

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
ELEKTROTEHNIČKI FAKULTET OSIJEK

Damir Blažević

**PREDVIĐANJE ODRŽAVANJA TEHNIČKOG
SUSTAVA PROCJENOM STANJA**

DOKTORSKA DISERTACIJA

Osijek, 2012.

Doktorska disertacija izrađena je u :

Zavodu za računalno i programsko inženjerstvo

Elektrotehničkog fakulteta Osijek

Sveučilišta J. J. Strossmayera u Osijeku

Mentor:

prof. dr. sc. Franjo Jović

Doktorska disertacija ima: 115 stranica

Rad broj:

SADRŽAJ:

1. UVODNA RAZMATRANJA	1
1.1. Uvod u problem	1
1.2. Zadaci i cilj rada	2
1.3. Metodološki okvir.....	3
2. ODRŽAVANJE TEHNIČKIH SUSTAVA.....	4
2. 1. Vrste održavanja	6
2.1.1. Održavanje nakon kvara	7
2.1.2. Periodičko održavanje.....	8
2.1.3. Održavanje prema stanju	9
2.1.4. Održavanje na osnovu procjene rizika.....	10
2.2 Aktivnosti održavanja i dekompozicija sustava.....	12
3. ODRŽAVANJE OPREME PROCJENOM STANJA	15
3.1. Temeljne značajke modela održavanja opreme procjenom stanja.....	15
3.2. Prikupljanje podataka	15
4. ALGORITAM EVIDENCIJSKOG ZAKLJUČIVANJA.....	17
4.1. Interpretacija numeričkih i kvalitativnih podataka	17
4.2. Procjena stanja sustava	18
5. POBOLJŠANI ALGORITAM EVIDENCIJSKOG ZAKLJUČIVANJA	22
5.1. Nadogradnja osnovnog algoritma evidencijskog zaključivanja	22
5.2. Očekivana konačna ocjena stanja objekta	24
6. ANALIZA ULAZNIH PODATAKA.....	27
6.1. Kontinuirana varijabla kao ulazni podatak	27
6.2. Vrijeme eksploatacije kao ulazni podatak	31
6.3. Diskretna varijabla kao ulazni podatak.....	34
7. DEKOMPOZICIJSKI MODEL I PROCJENA STANJA TRANSFORMATORA ...	38
7.1. Osnovni atributi	40
7.2. Procjena stanja	44
8. PREDVIĐANJE STANJA SUSTAVA SIVIM MODELOM.....	51
8.1. Algoritam sivog predviđanja	51
8.2. Predviđanje rezultata komatografske analize otopljenih plinova u ulju energetskog transformatora.....	56

9. RASPRAVA	69
9.1. Dekompozicijski model energetskog transformatora	69
9.1. Procjena stanja	69
9.3. Predviđanje	71
9.4. Daljnji razvoj predloženog modela.....	71
10. ZAKLJUČAK.....	73
10.1. Model održavanja tehničkih sustava procjenom stanja	73
10.2. Potvrđene postavljene hipoteze doktorske disertacije.....	73
10.3. Poboľjšani model održavanja procjenom stanja.....	74
10.4. Znanstveni doprinosi istraživanja i dalji razvoj predloženog modela održavanja	76
LITERATURA	77
SAŽETAK	89
ABSTRACT.....	90
ŽIVOTOPIS.....	91
PRILOZI	92
Prilog 1. Osnovni kod aplikacije za procjenu stanja.....	92
Prilog 2. Osnovni kod aplikacije za sivo predviđanje	101
Prilog 3. Grafički prilozi.....	110

POPIS SLIKA

Slika 2.1. Izvori informacija za pojedine vrste održavanja.....	7
Slika 2.2. Održavanje nakon kvara	8
Slika 2.3. Periodičko održavanje	9
Slika 2.4. Održavanje prema stanju	10
Slika 4.1. Dekompozicija trafostanice	18
Slika 4.2. Dvorazinska organizacija atributa	19
Slika 6.1. Podjela intervala mjerne veličine x u pet kvalitativnih razreda s pridruženim vjerojatnostima b_n	28
Slika 6.2. Normirane razine pouzdanosti pojedinih ocjena	29
Slika 6.3. Ocjenjivanje sinkroniziranosti prekidača	30
Slika 6.4. Ocjenjivanje komponente Poissonovom distribucijom kvarova na osnovu starosti komponente.	32
Slika 6.5. Vrijednosti pouzdanosti ocjena normirane na 100 % za rastavljač sa srednjim vremenom kvara $MTTF = 12$ mjeseci.....	33
Slika 7.1. Osnovna dekompozicija energetskog transformatora.....	39
Slika 7.2. Dekompozicija tekuće krute izolacije.....	40
P.3. Slika 7.3. Dekompozicijski model energetskog transformatora.....	110

POPIS TABLICA

Tablica 6.1. Transformacijska tablica za pretvorbu diskretnih stanja u kvalitativne ocjene	34
Tablica 6.2. Ocjenjivanje transformatora na osnovu stanja Buchholz releja.....	35
Tablica 7.1. Osnovni atributi dekimpozicijskog modela energetskog transformatora ...	41
Tablica 7.3. Procjene stanja energetskog transformatora u različitim vremenskim točkama	48
Tablica 8.1. Određivanje preciznosti predviđanja	55
Tablica 8.2. Izvorni podaci za osnovne attribute koromatografske analize.....	56
Tablica 8.3. Prilagođeni podaci za osnovne attribute koromatografske analize.....	57
Tablica 8.4. Predviđanje razine vodika na osnovu postojećih podataka	58
Tablica 8.5. Predviđanje razine metana na osnovu postojećih podataka.....	58
Tablica 8.6. Predviđanje razine vodika kotrljajućom metodom	59
Tablica 8.7. Predviđanje razine metana kotrljajućom metodom	60
Tablica 8.8. Predviđanje razine vodika, greška predviđanja, preciznost modela	62
Tablica 8.9. Predviđanje razine metana, greška predviđanja, preciznost modela	62
Tablica 8.10. Predviđanje razine acetilena, greška predviđanja, preciznost modela.....	62
Tablica 8.11. Predviđanje razine etilena, greška predviđanja, preciznost modela	63
Tablica 8.12. Predviđanje razine etana, greška predviđanja, preciznost modela.....	63
Tablica 8.13. Predviđanje razine ugljičnog monoksida, greška predviđanja, preciznost modela.....	63
Tablica 8.14. Predviđanje razine ugljičnog dioksida, greška predviđanja, preciznost modela.....	64
Tablica 8.15. Predviđanje razine vodika, greška predviđanja bez kontrolne vrijednosti	64
Tablica 8.16. Predviđanje razine metana, greška predviđanja bez kontrolne vrijednosti	65
Tablica 8.17. Predviđanje razine acetilena, greška predviđanja bez kontrolne vrijednosti	65
Tablica 8.18. Predviđanje razine etilena, greška predviđanja bez kontrolne vrijednosti	65
Tablica 8.19. Predviđanje razine etan, greška predviđanja bez kontrolne vrijednosti....	66
Tablica 8.20. Predviđanje razine ugljičnog monoksida, greška predviđanja bez kontrolne vrijednosti	66

Tablica 8.21. Predviđanje razine ugljičnog dioksida, greška predviđanja bez kontrolne vrijednosti	66
Tablica 8.22. Predviđanje razine ugljičnog dioksida, greška predviđanja bez kontrolne vrijednosti	67
Tablica 8.23. Procjene stanja energetskog transformatora u različitim vremenskim točkama	67
P.3. Tablica 7.2. Kvantitativni i kvalitativni podaci	110

POPIS SIMBOLA

E	- skup osnovnih atributa
e_i	- element skupa osnovnih atributa
H	- skup ocjena koje se dodjeljuju atributima
H_i	- ocjena iz skupa H
$K_{I(i)}$	- normirajući koeficijent
$m_{H,i}$	- ostatak težinske vjerojatnosti osnovnog i – tog atributa
$m_{n,i}$	- težinska vjerojatnost osnovnog i – tog atributa
$S(e_i)$	- procjena i – tog elementa iz skupa osnovnih atributa
t	- vrijeme
$u(y)$	- konačna ocjena stanja
u_{avg}	- srednja očekivana vrijednost konačne ocjene stanja
u_{max}	- najveća očekivana vrijednost konačne ocjene stanja
u_{min}	- najmanja očekivana vrijednost konačne ocjene stanja
ω_i	- relativna težina i – tog osnovnog atributa
σ	- standardno odstupanje
β_H	- stupanj nepotpunosti procjene
β_i	- stupanj uvjerenja u ocjenu H_i dodjeljenu i – tom atributu
$\beta_{n,i}$	- kombinirani stupanj uvjerenja
$x^{(0)}$	- niz ulaznih podataka
$x^{(l)}$	- akumulirani niz
$\hat{x}^{(0)}$	- niz predviđenih podataka
a	- parametar sivog modela
b	- parametar sivog modela
$\zeta^{(0)}(i)$	- greška predviđanja i -tog elementa
$\bar{\zeta}$	- prosječna pogreška
Δt	- promjena vremena
$\theta(t_i)$	- koeficijent vremenskog pomaka

1. UVODNA RAZMATRANJA

Iskustva u eksploataciji postrojenja pokazala su da najveći dio radnih sredstava i opreme ne gubi svoje karakteristike odjednom već da je to kontinuirani proces. U najvećem dijelu slučajeva, oštećenja, kvarovi i havarije u postrojenjima rezultat su postepenog trošenja i zamora opreme za vrijeme eksploatacije. Nagovještaj mogućeg kvara pojavljuje se znatno ranije. Za prepoznavanje stanja koje prethodi kvaru potrebno je posjedovati odgovarajuće metode, postupke i opremu za mjerenja odgovarajućih parametara, koji ukazuju na pojavu odstupanja od normalnog rada i nazivnih svojstava sustava.

1.1. Uvod u problem

Utvrđivanje stanja sustava u određenom trenutku naziva se tehnička dijagnostika i obuhvaća metode, postupke i sredstva za praćenje rada tehničkih sustava. Periodičkim ili kontinuiranim mjerenjem fizikalnih veličina bitnih za rad i stanje sustava, njihovom usporedbom s utvrđenim graničnim vrijednostima normalnog rada, možemo donijeti sud o trenutnom stanju sustava i na osnovu trenutnog stanja odlučiti o daljnjim aktivnostima održavanja.

Posebno su ova tehnička pitanja značajna u kada se razmatra elektroenergetski sustav (EES), ili njegovi dijelovi, koji predstavljaju vrlo složeni tehnički sustav s infrastrukturnim značajem za cjelokupno gospodarstvo, javne službe i stanovništvo na području svake države. Pravovremeno i ekonomski prihvatljivo održavanje opreme je preduvjet za sigurno funkcioniranje EES-a, a moguće ekonomske i tehničke direktne i indirektne štete zbog kvarova na opremi koje mogu nastati potencijalno su vrlo velike, gotovo neprocjenjive, tako da je pitanje održavanja opreme, odnosno pitanje kvalitetnih modela preventivnog održavanja u tehnici uvijek aktualno.

U ovom radu razmatrat će se mogući načini održavanja opreme i tehničkih sustava s posebnim naglaskom na održavanje procjenom stanja, a na primjeru energetskog transformatora u elektroenergetskom sustavu. Održavanje procjenom stanja jedan je od novijih pristupa problemu održavanja, a temelji se na uvidu u stanje postrojenja, na

osnovu čega se donose odluke o eventualnim postupcima održavanja. Primjenom predloženog modela u praksi moguće je postići značajan napredak u kvaliteti održavanja, a samim time i raspoloživosti održavanog tehničkog sustava, uz potencijalno smanjenje troškova, ulaganjem u napredne algoritme kao podrška odlučivanju, implementaciji sustava za kontinuirano praćenje i prikupljanje podataka te provođenjem redovitih mjerenja i pregleda.

1.2. Zadaci i cilj rada

Polazeći od uočenog problema definirani su slijedeći zadaci istraživanja:

- a) Opisati i pojasniti koncept održavanja tehničkih sustava s posebnim osvrtom na vrste održavanja i potrebne aktivnosti održavanja ;
- b) razmotriti i analizirati koncept održavanja opreme procjenom stanja;
- c) analizirati algoritam evidencijskog zaključivanja;
- d) analizirati poboljšani algoritam evidencijskog zaključivanja i mogućnost njegove implementaciju;
- e) izraditi dekompozicijski model tehničkog s odgovarajućim težinama osnovnih i općih atributa na primjeru energetskog transformatora (proizvođač Končar, tip 1ARZ 300000-420/A);
- f) na osnovu dekompozicijskog modela prikupiti potrebne podatke i ocjene osnovnih atributa;
- g) pokrenuti agregacijski proces nad prikupljenim ocjenama osnovnih atributa za više vremenskih točaka
- h) odrediti ocjene stanja energetskog transformatora i ukupnu ocjenu stanja za sve raspoložive vremenske točke
- i) primijeniti algoritam sivog predviđanja nad odabranim skupom podataka i dati predviđanje budućeg stanja na osnovu postojećih podataka
- j) definirati postupke za ocjenu uspješnosti predviđanja

U polazištu istraživanja postavljene su dvije hipoteze:

- a) Je li moguće stanje složenog tehničkog sustava adekvatno predstaviti jednom numeričkom vrijednošću (ili uređenim skupom vrijednosti) koja predstavlja kvalitativnu ocjenu stanja sustava i na osnovu te ocjene imati uvid u stanje sustava.

b) Je li moguće na osnovu izvršenih procjena stanja sustava u n vremenskih točaka procijeniti stanje sustava u $n+1$ točki.

Na osnovu teorijskih razmatranja i empirijskih istraživanja, a kao cilj rada, testirat će se postavljene hipoteze te u slučaju njihova potvrđivanja, konceptualno će se definirati poboljšani model primjene održavanja procjenom stanja te metoda predviđanja temeljena na teoriji sivih sustava [29], [30], [33].

1.3. Metodološki okvir

Tijekom istraživanja korišten je niz znanstvenih metoda, kvalitativnih i kvantitativnih; njihov je izbor ovisio o segmentu istraživanja. Od općih metoda korištene su: analiza, sinteza, indukcija, dedukcija, komparacija, deskriptivna i empirička metoda. Numerički postupci korišteni su u izračunima, a za istraživanja statističke kvalitativne i kvantitativne metode poput: modeliranja, prikupljanje podataka, programiranje i simulacije. Za analizu rezultata korištene su metode apstrakcije i konkretizacije. Numeričke serije su prikazane tablicama, a važnije relacije i grafičkim prikazima.

Svi proračuni prikazani u ovom radu izvode se uz pomoć za tu svrhu posebno razvijenih aplikacija čiji je osnovni kod prikazan u prilogu ovog rada. Zbog velikog broja obrađenih ulaznih podataka i veličine dekompozicijskog modela slike i tablice koje prelaze standardne dimenzije stranice smještene su u grafičkom prilogu rada.

2. ODRŽAVANJE TEHNIČKIH SUSTAVA

Liberalizacija i globalizacija tržišta kao svjetski trend u ekonomiji i proizvodnji utječu i na odabir tehnika vođenja i održavanja postrojenja. Postojećem trendu posebno doprinose spajanja tvrtki s različitom infrastrukturom, strateškom i informatičkom podrškom. Takve korporacije posjeduju postrojenja različitih starosnih dobi i rijetko su koja potpuno nova. U svakoj sredini gdje je cijena proizvodnje podložna tržišnom natjecanju na globalnoj razini, potrebno je pronaći optimum odnosno kompromis između investicija u razvoj, rekonstrukciju i održavanje postrojenja s jedne strane i tržišne cijene proizvoda, odnosno usluge s druge strane. Ne treba zaboraviti ni trend smanjenja potrebne radne snage, koji je posebno izražen u velikim sustavima poput sustava za proizvodnju, prijenos i distribuciju električne energije. U najvećem dijelu to je posljedica cijene ljudskog rada koja uvelike nadmašuje cijenu materijala i opreme potrebne za rad takvog sustava.

Tržišna konkurencija i želja za profitabilnim poslovanjem nameću preispitivanje postojećih i potragu za novim metodama održavanja tehničkih postrojenja. Pri odabiru odgovarajuće metode održavanja naročito korisnom pokazala se dokumentacija o ponašanju postrojenja, odnosno baze podataka ili baze znanja o vrstama kvarova, njihovoj učestalosti kao i o vijeku trajanja pojedinih dijelova ili cijelih postrojenja. Digitalizirana baza znanja s odgovarajućim informacijskim sustavom i potrebnim alatima za analizu postojećih podataka omogućava jednostavnije donošenje odluka temeljnih na objektivnoj informaciji i uz manju upotrebu radne snage. Za ovu svrhu razvijaju se posebni softverski paketi koji omogućavaju jednostavnije i efikasnije upravljanje postrojenjem [5], [88]. Uz pomoć takvih aplikacija moguće je, a na osnovu baza podataka i/ili znanja, jednostavnije donijeti odluku koji je način upravljanja i održavanja postrojenja primjeren u odgovarajućem trenutku. Povezivanjem takvih alata sa sustavom za upravljanje postrojenjem omogućava se dokumentiranje poduzetih mjera i kasnija analiza ispravnosti donesene odluke i pratećih posljedica na postrojenje ili proizvodni proces [86], [89]. Takav sustav pruža nam osnovu za promjenu ili korekciju korištene metode upravljanja odnosno održavanja.

Efikasno održavanje postrojenja s gledišta isplativosti poslovanja ima dvostruki utjecaj tj. smanjenje troškova proizvodnje s jedne i čuvanje postojećih resursa s druge strane. Nije naodmet istaknuti značaj koji održavanje postrojenja i za to zaduženi odjeli imaju u ukupnom poslovanju tvrtke. Gruba procjena sredstava koji se godišnje izdvajaju u svrhu održavanja postojećih postrojenja za tvrtke iznosi od 2 do 15 % ukupnih troškova [4], [10], [83], [95], [114]. Samo u Republici Njemačkoj taj iznos za industriju i privatni sektor dostiže 110 milijardi eura. Prema istom izvoru za održavanje na prostoru Evropske unije izdvaja se 11 do 12 % ukupnog bruto dohotka (BDP). Najveći iznosi za održavanje postrojenja izdvajaju se u Sjedinjenim Američkim Državama i približno iznose 4000 milijardi američkih dolara što je jednako BDP-u Japana ili BDP-u Azije i Afrike zajedno. Stalni pritisak za smanjenjem troškova proizvodnje zahtijeva uvođenje određenih mjera za povećanje efikasnosti upravljanja i održavanja postrojenja. Povećanje efikasnosti u pravilu se može ostvariti ispunjavanjem određenih preduvjeta kao: stalno prikupljanje i sortiranje podataka o postrojenju i komponentama postrojenja s ciljem povećanja pouzdanosti i smanjenja obveznih mjera održavanja, nabavka odgovarajućih alata tj. aplikacija za bolju organizaciju upravljanja i održavanja, transparentnost poslovanja, prikaz svih troškova i procjena opravdanosti pojedinih ulaganja. Uspješnost provođenja navedenog zahtijeva aktualno znanje o tehničkim i ekonomskim uvjetima rada postrojenja, pristup i analizu velike količine informacija i prikupljenih podataka te je stoga nužno postojanje efikasnog informacijskog sustava temeljenog na modernim hardverskim i softverskim rješenjima [7], [9], [28], [32], [81].

Proces eksploatacije tehničkog sustava narušava se degradacijom njegovih performansi. U cilju održavanja razine proizvodnje, negativne promjene na tehničkom sustavu moraju se spriječiti određenim protumjerama, a u cilju da se obnovi originalna operabilnost sustava. Mjere koje se u tom slučaju poduzimaju nazivamo održavanjem.

Definiciju održavanja kao tehnološkog postupka možemo odrediti kao mjere potrebne za održavanje i obnavljanje nominalnog stanja objekta ili postupke vezane uz određivanje i procjenu trenutnog stanja tehničkih objekata i sustava.

Ukoliko sustav posjeduje trenutno ispravno nominalno stanje sustava U_k njegovom eksploatacijom imamo određeno negativno djelovanje na sustav i sustav dolazi do stresnog stanja U_s . Ukoliko je eksploatacija odnosno djelovanje stresa na sustav bilo u normalnim granicama, odnosno količina stresa S je manja od kritične razine S_k (razina koju sustav može podnijeti) tada imamo sustav podvrgnut uobičajenom trošenju i kod

takvog sustava možemo očekivati da je podlegao utjecajima habanja, starenja, korozije, djelovanju nečistoća i sl. Ukoliko je sustav bio izložen stresu veće razine od kritične *Sk* tada možemo reći da je sustav bio preopterećen i u ovom slučaju možemo očekivati lomove, napuknuća, deformacije, zapaljenja pa čak i eksplozije. Rezultat u oba slučaja je određeno štetno djelovanje na sustav. U prvom slučaju to je stalno habanje odnosno zamor i degradacija sustava, a u drugom slučaju govorimo o nastanku nekontrolirane, odnosno spontane štete. U praksi najčešće imamo kombinaciju normalnog rada i preopterećenosti sustava što rezultira stalnim habanjem i degradacijom sustava i pojavom nekontrolirane odnosno spontane štete na sustavu.


Slijedeći korak nakon procjene štete je održavanje, a ono podrazumijeva prevenciju, dijagnosticiranje i analizu stanja te popravak. Norma DIN 31 051 aktivnosti održavanja naziva opsluživanje, inspekcija i popravak [10], [69], [95], [96].

2. 1. Vrste održavanja

Postoji više metoda koje pokušavaju dati rješenje problemu održavanja tehničkih sustava i svaka ima svoje specifične ciljeve i zadatke. Možemo izdvojiti nekoliko karakterističnih metoda: Održavanje prema stanju (eng. *Condition Based Maintenance*, CBM), Održavanje prema razini pouzdanosti (eng. *Reliability Centered Maintenance*), Održavanje samo bitnih dijelova sustava (eng. *Lean Maintenance*), Održavanje prema ukupnom životnom ciklusu (eng. *Total Lifecycle Costs Strategy*), Održavanje prema proizvodnji (eng. *Total Productive Maintenance*) [10], [34], [69], [95].

Kvalitetna strategija održavanja nekog sustava mora biti odabrana sukladno samom sustavu i najčešće će kombinirati sve gore navedene metode. Da bi dobili odgovor na pitanje koju strategiju održavanja odabrati da bi sustav bio ekonomski efikasniji i na tržištu konkurentniji moramo uzeti u obzir gubitke u proizvodnji nastale kao posljedica kvara, smanjenje troškova održavanja i organizacijskih troškova. Možemo zaključiti da se povećanje efikasnosti održavanja može izvesti uz pomoć uvida u stanje sustava, informacijske podrške u donošenju odluka i optimizacije postupaka održavanja. Slika 2.1. prikazuje izvore informacija za pojedine metode održavanja. Nakon prikupljanja informacija o stupnju i funkciji zamora pojedinih komponenti sustava i statistike stohastičkih kvarova u mogućnosti smo odabrati određenu metodu održavanja. Odabrana strategija održavanja odabire se na osnovu podataka dobivenih iz ponašanja

sustava i definira odabranu vrstu održavanja, vrijeme potrebno za provođenje održavanja kao i same ciljeve održavanja.




Slika 2.1. Izvori informacija za pojedine vrste održavanja

Svrha odabrane strategije je što bolje ispunjenje ciljnih funkcija održavanja. Ciljne funkcije najčešće se odnose na povećanje upotrebljivosti sustava, osiguravanje određenog stupnja pouzdanosti, optimizacije broja zaposlenih, smanjenje ukupnog troška i sl. Ciljne funkcije ovise o sustavu koji je predmet održavanja, cjelokupnoj ekonomskoj situaciji tvrtke, kao i o odabranoj strategiji održavanja. Prva odluka vezana uz odabir odgovarajuće strategije je odgovor na pitanje: kada treba započeti s održavanjem? Samo su dvije mogućnosti, prije pojave kvara ili nakon kvara. Odabrani odgovor uvjetuje hoće li ili neće biti preventivnog djelovanja na sustav.

2.1.1. Održavanje nakon kvara

Održavanje sustava nakon pojave kvara (eng. *Failure maintenance, Breakdown maintenance*) djeluje nakon kvara i ovisno je o vrsti i težini kvara ili pogreške. Kod ovakvog održavanja nema preventivnih djelovanja. Kvarovi ili pogreške obično vode do zaustavljanja cijelog sustava i/ili prekida u proizvodnji i u takvoj situaciji potrebno je donijeti odluku, u smislu što manjih gubitaka u poslovanju, da li će održavanje biti minimalno s ciljem što bržeg uspostavljanja operativnog stanja ili će se ići u značajniju

obnovu sustava. U svrhu smanjenja vremena za održavanje sve potrebne aktivnosti mogu se unaprijed planirati npr. potrebno osoblje, materijal, tehnologija, i sl., osim ukupnog vremena potrebnog za izvođenje održavanja. Na slici 2.2. prikazan je vremenski dijagram s mogućom pojavom kvarova i njihovim otklanjanjem.




Slika 2.2. Održavanje nakon kvara

Prednost ovakvog pristupa je u potpunom iskorištenju rezervi dijela sustava na kojem se dogodio kvar. Nedostatak ovog pristupa je nepredvidivost trajanja i vrste potrebnih popravaka i mogućnost pojave sekundarne štete odnosno štete na drugim dijelovima sustava prouzročene prvobitnim kvarom.

2.1.2. Periodičko održavanje

Kod periodičkog održavanja (eng. *Time based maintenance*) pristup održavanju sustava i zahvati na sustavu unaprijed se planiraju i odvijaju se u određenim vremenskim intervalima. Ukoliko dođe do kvara unutar vremenskog razdoblja između dva zakazana zahvata vrše se samo minimalni zahvati s ciljem vraćanja sustava u funkcionalno stanje. Ukoliko je vremenski ciklus održavanja na izmaku ili otklanjanje kvara zahtjeva veće zahvate moguće je istovremeno otkloniti kvar i obaviti redovito održavanje sustava i na taj način započeti novi ciklus održavanja. Spajanje redovitog održavanja i otklanjanja kvara dovodi i do promjene ciklusa redovitog održavanja. Ukoliko je riječ o godišnjem ciklusu tada bi gašenje postrojenja zbog održavanja odnosno remonta moglo dospjeti i u drugo godišnje doba. Takvi pomaci u velikom broju slučajeva mogu dovesti do negativnih pojava i najčešće se izbjegavaju te se ostaje na prvobitnom planu održavanja. Tako je npr. kod sustava proizvodnje i distribucije toplinske energije, kritično vremensko razdoblje za rad sustava sezona grijanja. Za to vrijeme ne smije doći do zastoja u radu ili bi zastoj trebao biti minimalan. U slučaju zastoja u radu za vrijeme

sezone gubitci su najveći i potrebno je sustav osposobiti u što kraćem vremenskom periodu. Kod ovog sustava vrijeme pogodno za prekid rada, održavanje, remont i pripremu sustava za novi ciklus je vrijeme van sezone grijanja odnosno ljeto i jesen, kada sustav radi s minimalnim kapacitetom. Slika 2.3. prikazuje vremenski dijagram učestalosti redovitih održavanja i pojavu kvara.




Slika 2.3. Periodičko održavanje

Prednost periodičkog održavanja je ta što se svi zahvati kao i potrebno vrijeme za redovito održavanje unaprijed planiraju. Nedostatak ovakvog pristupa leži u činjenici da se dužina ciklusa predviđa na osnovu statističkih pokazatelja i to može dovesti do predugog ciklusa (povećan broj kvarova unutar jednog ciklusa) ili od kratkog ciklusa u kojem se djelomično ili neadekvatno iskorištavaju rezerve sustava ili rezerve pojedinih dijelova sustava. Ovim pristupom može se osigurati vrlo visoka pouzdanost i raspoloživost održavanog sustava, koju naravno prati i visoka cijena održavanja.

2.1.3. Održavanje prema stanju

Održavanje prema stanju (eng. *Condition based maintenance*) je zapravo kombinacija dva već spomenuta pristupa tj. periodičkog održavanja i održavanja nakon kvara [16], [50], [70]. Ideja je iskoristiti prednosti održavanja nakon kvara odnosno što većeg iskorištenja rezervi komponenata i dijelova sustava i istovremeno izbjeći nedostatke periodičkog održavanja. Održavanje prema stanju koristi sve dostupne metode radi određivanja tehničke razine stanja sustava i opreme s ciljem da se održavanju pristupi tek kada stanje komponenti sustava padne ispod određene kritične razine [1]. Stanje sustava određuje se testovima, inspeksijskim pregledima, dijagnozom, mjerenjem i analizom izmjerenih podataka [2], [3]. Slika 2.4. prikazuje vremenski dijagram izvođenja mjerenja i dijagnoze nad sustavom i poduzimanja određenih zahvata. Pregledi

sustava održavaju se u redovitim vremenskim intervalima T_i , te ukoliko stanje sustava to zahtijeva pristupa se održavanju odnosno zamjeni dijelova sustava koji to zahtijevaju. Ukoliko ipak dođe do kvara on se otklanja minimalnim zahvatima.



Slika 2.4. Održavanje prema stanju

Prednosti ovakvog pristupa su visoka pouzdanost i maksimalna iskoristivost rezervi dijelova sustava. Nedostatci su što sustav ovisi o mogućnosti provođenja adekvatnih mjerenja i pouzdanosti postavljenje dijagnoze sustava. Također kako se vrijeme za izvođenje remonta ne planira već ovisi isključivo o stanju sustava, može se dogoditi da izvođenje većih zahvata na sustavu padne u neodgovarajuće vrijeme, odnosno vrijeme kada tržište zahtijeva visoku raspoloživost sustava. Održavanje prema stanju biti će detaljnije prikazano u slijedećem poglavlju.

2.1.4. Održavanje na osnovu procjene rizika

Kod donošenja odluka u vezi s izvođenjem održavanja razlikujemo dvije vrste rizika. Prvi bi bio rizik u smislu sigurnosti i pouzdanosti proizvodnje, a pod drugom vrstom rizika podrazumijevamo rizik u procjeni troška održavanja sustava i održavanja proizvodnje. Rizik vezan uz procjenu cijene održavanja i proizvodnje može se izraziti kao umnožak učestalosti kvara i visini nastale štete. Izraz (2.1) prikazuje rizik R za provođenje ili ne provođenje održavanja, gdje je H učestalost pojave kvarova ili nepravilnosti, a S predstavlja razinu nastale štete.

$$R = H \cdot S \quad (2.1)$$

Učestalost kvarova H određuje se uz pomoć statističkih metoda i teorije pouzdanosti, dok se razina nastale štete S određuje kao cijena zastoja u proizvodnji uvećana za cijenu održavanja odnosno otklanjanja kvara.

Ukupan iznos rizika za neki sustav određuje se kao suma rizika za pojedine dijelove sustava, što je prikazano slijedećim izrazom:

$$R = \sum_{i=1}^n R_i = \sum_{i=1}^n S_i \cdot H_i \quad (2.2)$$

gdje je R_i rizik vezan uz i -tu komponentu, S_i pripadajući trošak te H_i učestalost pojave kvara na i -toj komponenti.

Trošak vezan uz pojedinu komponentu sustava definira se kao trošak odnosno cijena zastoja u proizvodnji i trošak popravaka preko slijedećeg izraza:

$$S_i = W_s \cdot t_i \cdot L_i + K_i \quad (2.3)$$

gdje je S_i trošak vezan uz i -tu komponentu, W_s iznos jediničnog gubitka zbog zastoja u proizvodnji, t_i vrijeme potrebno za popravak komponente, L_i količina, broj jediničnih gubitaka, K_i trošak popravka.

Procjena učestalosti kvarova donosi se na osnovu podataka o prijašnjim kvarovima i ne možemo je smatrati pouzdanom. Također, informacije od strane proizvođača opreme često su nedostupne ili teško upotrebljive u stvarnoj radnoj okolini. Sa stajališta sigurnosti potrebno je koristiti drugačiju i složeniju analizu podataka od ove netom prikazane.


Posebnu pažnju potrebno je posvetiti razlikovanju između individualnih komponenti sustava u smislu izlaganja riziku, jer zapravo mali broj komponenti značajno utječe na iznos sveukupnog rizika.

Cilj ukupnog inženjerskog rada na području održavanja bio je i ostao svođenje sigurnosnog rizika na minimalnu razinu. Naziv održavanje na osnovu procjene rizika ne treba dovoditi u vezu s povećavanjem rizika i većom mogućnosti pojave neželjenih posljedica po ljude, opremu i sl. već zapravo suprotno, riječ je svođenju ukupnog rizika na najmanju moguću mjeru. Odluke koje mogu utjecati na smanjenje sigurnosti zaposlenika, zagađenje okoliša, i općenito dovesti do negativnih posljedica po okolinu ne smiju se donositi samo na osnovu procjene rizika kao troška održavanja. Tek kada

smo sigurni da donesene odluke neće povećati opasnost postrojenja po okolinu možemo donijeti odluke na osnovu rizika samo kao troška.

2.2 Aktivnosti održavanja i dekompozicija sustava

Industrijsko postrojenje je složen sustav sačinjen od nekoliko podsustava ili individualnih dijelova, komponenti. Stanje svakog dijela izravno utječe na ukupno stanje sustava. Na slici 2.4. prikazana je jednopolna shema trafostanice, dijela elektroenergetskog sustava, u čijem sastavu je i energetski transformator, uređaj tj. objekt koji će u nastavku rada biti detaljnije proučavan.



Sl. 2.5. Jednopolna shema dijela trafostanice

Bitno je primijetiti da se takav složeni energetski objekt sastoji od više različitih podsustava koji se opet mogu podijeliti na jednostavnije sustave ili uređaje sve dok se ne dođe do najnižeg stupnja, objekta ili uređaja. Svaki od ovako podijeljenih objekata utječe s određenom težinom na ponašanje cijelog sustava. Da bi odabrali najpovoljniji pristup održavanju potrebno je načiniti i pravilnu dekompoziciju promatranog postrojenja odnosno rastavljanje složenog sustava na jednostavnije dijelove s stajališta održavanja. Mogući su razni pristupi dekompoziciji i dekompoziciju najčešće izvodi ekspert tj. osoba s visokim stupnjem znanja o proizvodnom procesu, radu i održavanju

promatranog sustava. Prva podjela koju je moguće načiniti je podjela sustava po prioritetima. To znači podijeliti opremu u razrede po stupnju nužnosti za funkcioniranje sustava. U najjednostavnijem slučaju to znači podijeliti dijelove sustava u dva razreda kao dijelove bitne odnosno nužne za rad sustava i nebitne odnosno dijelove ili opremu bez koje sustav može barem neko vrijeme raditi. Takva podjela najjednostavnije se vrši na osnovu empirijskih podataka za promatrani sustav.

Detaljnija podjela sustava u odgovarajuće razrede može se izvesti prema posljedicama mogućeg kvara na sustavu, dijelovima sustava ili pojedinačnoj opremi. Sukladno rečenom dijelove sustava možemo podijeliti u pet razreda na slijedeći način:

- sustav ili dijelovi sustava čiji kvar bitno utječe smanjenje sigurnosti postrojenja ili može izazvati kvarove drugih dijelova sustava
- sustav ili dijelovi sustava čiji kvar može dovesti do potpunog zastoja postrojenja
- sustav ili dijelovi sustava čiji kvar vodi do smanjenja proizvodnje
- sustav ili dijelovi sustava čiji kvar utječe na smanjenje efikasnosti glavnog proizvodnog procesa
- i sustav ili dijelovi sustava čiji kvar nema direktnog utjecaja na proizvodni proces.

Ovakva podjela sustava pokazala se korisnim pristupom za razne industrijske segmente, a posebno za postrojenja vezana uz proizvodnju, prijenos i distribuciju električne energije [49], [105], [114], [109].

U slučajevima sustava s velikom učestalosti kvarova ili velikom osjetljivošću na kvarove može se klasificirati sustav prema postupcima održavanja sustava umjesto klasifikacije prema dijelovima sustava. Jedna od mogućih podjela bila bi slijedeća:

- provođenje održavanja od strane prve slobodne osobe
- provođenje održavanja unutar trideset minuta
- provođenje održavanja u prvom slobodnom terminu
- provođenje održavanja unutar 3 mjeseca

Za navedeni pristup potrebno je imati određeni broj zaposlenika stalno dostupan i u blizini postrojenja kako bi mogli reagirati u slučajevima s najvećim prioritetom.

Posebnu pažnju treba posvetiti dostupnosti provođenja održavanja u određenom sustavu. Treba uzeti u obzir da je u većini slučajeva prije početka provođenja održavanja potrebno poduzeti određene predradnje tj. okoliš postrojenja ili cijelo

postrojenje mora se dovesti u sigurno stanje po osobe koje provode održavanje. Npr. pogon za proizvodnju električne energije treba se isključiti, temperaturu, tlak svesti na uvjete pogodne za rad, za rad na visini poduzeti odgovarajuće zaštitne mjere poput zaštitnog užeta i sl. U tom smislu provođenje poslova održavanja postrojenja može se podijeliti u slijedeće razrede:

- provođenje za vrijeme pogona postrojenja
- dio postrojenja isključen, okoliš s radnim parametrima postrojenja (operating environment)
- dio postrojenja isključen, parametri okoliša svedeni na sigurne uvjete (ambient environment level)
- cijeli pogon isključen, sustavi ispušteni, očišćeni i svedeni na uvjete okoliša.

Ovakve podjele sustava česte su u električnim i kemijskim postrojenjima.

3. ODRŽAVANJE OPREME PROCJENOM STANJA

Održavanje prema stanju tehničkih objekata ili sustava zasniva se na trenutnom fizičkom ili parametarskom stanju promatranog objekta. Ovakav pristup održavanju prilično je zahtijevan zbog nužnosti redovitih inspekcijskih pregleda i nadzora promatranog objekta odnosno sustava. Bitno je istaknuti da ovakvim pristupom postizemo optimalnu iskorištenost životnog ciklusa objekta.

3.1. Temeljne značajke modela održavanja opreme procjenom stanja

Procjena stanja promatranog objekta izvodi se na licu mjesta od strane zaposlenika ili udaljeno uz pomoć opreme za daljinsko motrenje i nadgledanje sustava. S napretkom u komunikacijskoj i informacijskoj tehnici oprema za udaljeno nadgledanje tehničkih sustava postala je dostupna i pristupačna poslovnim subjektima. Analiza uložених sredstava u opremu za udaljeni nadzor i analiza na taj način stečenih mogućnosti i usluga potvrđuje isplativost ulaganja u takve sustave [3], [33], [101]. Informacije i veličine bitne za rad i održavanje tehničkog sustava nužno je prikupljati često, a ponekad i kontinuirano. Ukoliko se takve veličine mogu i mjeriti na relativno jednostavan način tada kažemo da je sustav pogodan za kontinuirano inteligentno motrenje odnosno, kontinuirano prikupljanje informacija o radu i stanju sustava uz pomoć opreme za mjerenje, daljinsko očitavanje i prijenos prikupljenih podataka. Takve informacije se prikupljaju, lokalno obrađuju i pripremaju, a zatim prenose u centralni dio sustava za nadgledanje gdje se vrši daljnja obrada prikupljenih podataka [8], [11], [12]. U centralnom dijelu sustava za nadgledanje i obradu prikupljenih informacija na raspolaganju su složene metode i algoritmi za analizu, obradu i pohranu prikupljenih podataka [19], [27], [99].

3.2. Prikupljanje podataka

Unatoč modernoj i razvijenoj opremi za nadgledanje sustava postoje određene informacije o sustavu koje se zbog složenog postupka mjerenja ili same prirode informacije ne mogu na taj način prikupljati npr. uljna kromatografija [31], opće stanje

objekta, stupanj korozije i sl.. U svrhu prikupljanja informacija takovog tipa potrebno je sudjelovanje školovanog i posebno izučenog kadra koji je sposoban obaviti mjerenje ili dati procjenu stanja objekta odnosno sustava. S obzirom na način prikupljanja informacija možemo reći da postoje dva različita tipa podataka. Prvi tip podataka možemo nazvati dinamičkim informacijama i takve informacije se prikupljaju uz pomoć opreme za udaljeno nadgledanje, prikupljanje i prijenos podataka [60], [67], [73], [80], [90]. Drugi tip podataka su statičke informacija do kojih se dolazi na licu mjesta odnosno mjerenjem ili procjenom eksperta na samom sustavu [47], [79], [76], [82].

Na osnovu prikupljenih informacija, dinamičkih ili statičkih, donose se odluke o održavanju sustava [61], [62], [65], [66], [72]. Prikupljene informacije se na odgovarajući način obrađuju i interpretiraju [11], [12], [83]. Analiza stanja objekata [121] pokazuje da stanje određenog promatranog objekta najčešće ovisi o stanju više različitih atributa i da je za određivanje trenutnog stanja objekta potrebno koristiti analizu odlučivanja zasnovanu na više atributa (eng. Multiple Desicion Data Analisys, MADA) [6], [18], [42], kombiniranu s činjeničnim odnosno evidencijskim zaključivanjem (eng. *evidential reasoning*) [46], [84], [116].

4. ALGORITAM EVIDENCIJSKOG ZAKLJUČIVANJA

Da bi se ispravno ocijenilo stanje tehničkog sustava potrebno je prilikom izračuna u obzir uzeti veću količinu numeričkih i kvalitativnih podataka. Za svrhu interpretacije numeričkih i kvalitativnih vrijednosti potrebno je koristiti odgovarajuću semantiku tj. odgovarajući računalni aparat.

4.1. Interpretacija numeričkih i kvalitativnih podataka

Rezultat procjene stanja tehničkog sustava su naprijed definirane i rangirane ocjene s određenim stupnjem uvjerenja odnosno sigurnosti u ispravnost dodijeljene ocjene. Na osnovu procjene stanja donosi se odluka o djelovanju odnosno o postojanju potrebe za održavanjem [56], [59]. Svrha održavanja je podizanje stanja tehničkog sustava na višu razinu ukoliko je trenutna razina stanja kritično loša.

Pretpostavimo da procjene stanja tehničkog sustava mogu biti: loše, dovoljno dostatno, prosječno dobro, vrlo dobro i izvrsno. Navedene ocjene odgovaraju uobičajenim numeričkim ocjenama od 1 do 5. da bi uspješno procijenili stanje nekog tehničkog sustava potrebno je uspostaviti određenu hijerarhiju među atributima odnosno dijelovima sustava. Pogledajmo primjer hijerarhijskog sustava na slici 4.1. Vidljivo je da se atributi više razine ocjenjuju uz pomoć pripadajućih atributa niže razine. Atributi na najnižoj razini nazivamo osnovni atributi, a njima nadređeni su tzv. opći atributi. Hijerarhijskih razina može biti proizvoljno mnogo. Ukoliko utjecaj nekog atributa nismo u mogućnosti odrediti možemo ostaviti odgovarajući stupanj neodređenosti u procjeni stanja atributa, a time i cjelokupnog sustava. Tako na primjer prilikom procjene stanja transformatorskog ulja procjenitelj može biti:

- 40 % siguran da je koncentracija plinova u ulju na prosječnoj razini i 50 % siguran da je koncentracija plinova na vrlo dobroj razini
- potpuno siguran u ocjenu da je nivo vlage u ulju na razini vrlo dobar
- 50 % siguran da je razina starosti ulja na prosječnoj razini i 50 % siguran da je da je na razini vrlo dobar

U navedenim procjenama postotni omjeri 40 %, 50 % i 100 % su stupnjevi uvjerenja u ispravnost dane procjene i možemo ih pisati i u decimalnom obliku kao 0,4, 0,5, i 1.




Slika 4.1. Dekompozicija trafostanice

Potrebno je istaknuti da je procjena prvog atributa nepotpuna tj. ukupni stupanj uvjerenja iznosi 0,9, dok su u preostala dva slučaja procjene potpune (razina vlage i starost ulja). Razlika koja nedostaje u procjeni prvog atributa predstavlja stupanj nesigurnosti tj. neodređenosti (eng. *uncertainty*) u procjeni odnosno nedovoljno poznavanje osnovnih atributa koji utječu na promatrani opći atribut.

4.2. Procjena stanja sustava

Problem s kojim se susrećemo je ispravno predstaviti ukupnu procjenu stanja atributa. U ovom slučaju ulja u transformatoru, uzimajući u obzir sva tri spomenuta osnovna atributa. Originalni model algoritma evidencijskog zaključivanja zasnovan na Dempster-Shafer teoriji [6], [59], [84], [118] slijedi, a nakon toga slijedi razrada i unaprjeđenje osnovnog algoritma s Yang –Xu aksiomima [112], [113], [115].

Pretpostavimo jednostavnu dvorazinsku hijerarhiju atributa. Opće svojstvo ili opći atribut nalazi se na gornjoj razini, a više osnovnih atributa nalazi se na nižoj, donjoj razini. Organizacija atributa prikazana je na slici 4.2.



Slika 4.2. Dvorazinska organizacija atributa

Možemo pretpostaviti da postoji L osnovnih atributa e_i ($i = 1, \dots, L$) i da su svi oni povezani s općim atributom Y . U tom slučaju moguće je definirati skup osnovnih atributa

$$E = \{e_1, \dots, e_i, \dots, e_L\}. \quad (4.1)$$

Također možemo pretpostaviti da su težine atributa predstavljene s $\omega = \{\omega_1, \dots, \omega_i, \dots, \omega_L\}$ gdje je ω_i relativna težina i -tog osnovnog atributa e_i s vrijednošću između 0 i 1 ($0 \leq \omega_i \leq 1$). Težine atributa su bitne prilikom procjene stanja opreme i procjenjujemo ih uz pomoć različitih metoda. Da bi procijenili stanje atributa potrebno je definirati skup mogućih ocjena stanja. Pretpostavimo da su ocjene predstavljene sljedećim skupom:

$$H = \{H_1, \dots, H_n, \dots, H_N\}, \quad (4.2)$$

Gdje se pretpostavlja da je ocjena H_{n+1} veća, odnosno predstavlja bolje stanje od ocjene H_n , odnosno da je skup elemenata H uređeni skup elemenata počevši od najnižeg prema elementu s najvišom vrijednosti. Tada procjenu i tog elementa skupa osnovnih atributa e_i možemo predstaviti s sljedećim izrazom:

$$S(e_i) = \{(H_n, \beta_{n,i}), \quad n = 1, \dots, N\} \quad i = 1, \dots, L; \quad (4.3)$$

gdje $\beta_{n,i}$ predstavlja stupanj uvjerenja gdje je $\beta_{n,i} \geq 0$, $\sum_{n=1}^N \beta_{n,i} \leq 1$. Ukoliko je $\sum_{n=1}^N \beta_{n,i} = 1$

tada kažemo da je procjena stanja $S(e_i)$ potpuna. U suprotnom, ukoliko je

$\sum_{n=1}^N \beta_{n,i} < 1$ kažemo da je procjena stanja promatranog objekta $S(e_i)$ nepotpuna.

Poseban slučaj dan je sljedećim izrazom

$$\sum_{n=1}^N \beta_{n,i} = 0 \quad (4.4)$$

i ukazuje na potpuni nedostatak informacije o atributu e_i . Djelomičan ili potpuni nedostatak informacije o određenom atributu, nužnih za donošenje odluka, nije rijetka pojava. U tom slučaju je vrlo bitno kako će se s tim nedostatkom ili manjkom informacije postupati.

Neka je H_n ocjena, a β_n stupanj uvjerenja na koju je procijenjen opći atribut. U ovom slučaju potrebno je izračunati stupanj uvjerenja β_n tako da se u obzir uzmu procjene stanja svih odgovarajućih osnovnih atributa e_i . Postupak izračuna ocjene i stupnjeva uvjerenja za opći atribut na osnovu informacija vezanih uz osnovne attribute naziva se agregacijski proces. U tu svrhu koristi se sljedeći algoritam.

Neka je $m_{n,i}$ težinska vjerojatnost osnovnog atributa odnosno veličina koja predstavlja vrijednost ili stupanj kojom osnovni i -ti atribut e_i podupire sud da se osnovni atribut y može procijeniti na vrijednost unaprijed definirane ocjene H_n . Također, pretpostavimo da je $m_{H,i}$ ostatak težinske vjerojatnosti odnosno nedodijeljena vrijednost vjerojatnosti uzevši u obzir sve dodijeljene ocjene N za promatrani atribut e_i . Izračun težinskih vjerojatnosti dan je sljedećim izrazom:

$$m_{n,i} = \omega_i \beta_{n,i} \quad n=1, \dots, N; \quad (4.5)$$

gdje je ω_i vrijednost dobivena normiranjem težina osnovnih atributa. Postupak normiranja težina osnovnih atributa biti će opisan u sljedećem odjeljku. Ostatak težinske vjerojatnosti računa se prema izrazu:

$$m_{H,i} = 1 - \sum_{n=1}^N m_{n,i} = 1 - \omega_i \sum_{n=1}^N \beta_{n,i} \quad (4.6)$$

Pretpostavimo da je $E_{I(i)}$ podskup prvih i atributa $E_{I(i)} = \{e_1, e_2, \dots, e_i\}$ i sukladno tome pretpostavimo da je $m_{n,I(i)}$ težinska vjerojatnost definirana kao stupanj kojim svi i atributi podupiru sud kojim je atribut y procijenjena na ocjenu H_n . Također $m_{H,I(i)}$ je ostatak težinske vjerojatnosti nedodijeljen pojedinim ocjenama nakon što su procijenjeni svi osnovni atributi $E_{I(i)}$. Težinske vjerojatnosti $m_{n,I(i)}$, $m_{H,I(i)}$ za $E_{I(i)}$ mogu se izračunati iz osnovne težinske vjerojatnosti $m_{n,j}$ i $m_{H,j}$ za sve $n=1, \dots, N$, i $j=1, \dots, i$. Uzimajući u obzir sve navedene činjenice originalni rekurzivni algoritam evidencijskog zaključivanja možemo prikazati uz pomoć sljedećih izraza:

$$m_{n,I(i+1)} = K_{I(i+1)} (m_{n,I(i)} m_{n,i+1} + m_{n,I(i)} m_{H,i+1} + m_{H,I(i)} m_{n,i+1}) \quad n=1, \dots, N \quad (4.7)$$

$$m_{H,I(i+1)} = K_{I(i+1)} m_{H,I(i)} m_{H,i+1} \quad (4.8)$$

$$K_{I(i+1)} = \left[1 - \sum_{t=1}^N \sum_{\substack{j=1 \\ j \neq t}}^N m_{t,I(i)} m_{j,i+1} \right]^{-1} \quad i = 1, \dots, L-1 \quad (4.9)$$

Gdje je $K_{I(i+1)}$ normirajući koeficijent takav da je uvjet dan izrazom

$$\sum_{n=1}^N m_{n,I(i+1)} + m_{H,I(i+1)} = 1 \text{ zadovoljen. Važno je istaknuti da su osnovni atributi } E_{I(i)}$$

proizvoljno poredani i da njihove početne vrijednosti iznose $m_{n,I(1)}=m_{n,1}$ i $m_{H,I(1)}=m_{H,1}$.

Konačno u originalnom algoritmu evidencijskog zaključivanja kombinirani stupanj uvjerenja za opći atribut β_n je dan sa sljedećim izrazima:

$$\beta_n = m_{n,I(L)}, \quad n = 1, \dots, N \quad (4.10)$$

$$\beta_H = m_{H,I(L)} = 1 - \sum_{n=1}^N \beta_n \quad (4.11)$$

gdje β_H označava stupanj nepotpunosti procjene.

5. POBOLJŠANI ALGORITAM EVIDENCIJSKOG ZAKLJUČIVANJA

Poboljšani algoritam evidencijskog zaključivanja nastavlja se na osnovni algoritam evidencijskog zaključivanja i pridružuje mu aksiome za sintezu nužne za objektivno i smisleno zaključivanje.

5.1. Nadogradnja osnovnog algoritma evidencijskog zaključivanja

Da bi agregacijski proces bio objektivn i smislen nužno je definirati određene aksiome za sintezu. Sljedeći aksiomi za sintezu agregacijskog postupka predstavljeni su od Young - Xu [53], [115], [121].

Aksiom 1: opći atribut y ne može se procijeniti ocjenom H_n ukoliko niti jedan od osnovnih atributa skupa E nije procijenjen ocjenom H_n . Ovaj aksiom se još naziva i aksiom neovisnosti. On znači da ako je $\beta_{n,i}=0$ za sve $i=1, \dots, L$, tada je $\beta_n=0$.

Aksiom 2: opći atribut y trebao bi biti precizno ocijenjen ocjenom H_n ukoliko su svi osnovni atributi skupa E precizno ocijenjeni ocjenom H_n . Ovaj aksiom naziva se još i aksiom koncenzusa. On znači da ukoliko je $\beta_{k,i}=1$ i $\beta_{n,i}=0$ za sve $i=1, \dots, L$ i $n=1, \dots, N$, $n \neq k$, tada je $\beta_k=1$ i $\beta_n=0$ ($n=1, \dots, N$, $n \neq k$).

Aksiom 3: ukoliko su svi osnovni atributi skupa e u potpunosti procijenjeni na određeni skup ocjena, tada bi i opći atribut y trebao biti procijenjen na isti podskup ocjena. Ovo svojstvo naziva se još i aksiom potpunosti.

Aksiom 4: ukoliko je procjena nekog od osnovnih atributa iz skupa E nepotpuna do određenog stupnja tada će i opći atribut y biti procijenjen nepotpunom ocjenom. To svojstvo nazivamo aksiomom nepotpunosti.

Moguće je pokazati da originalni algoritam evidencijskog zaključivanja ne zadovoljava u potpunosti navedene aksiome [112], [116], [118]. Da bi osigurali ispunjavanje gore navedenih aksioma predstavljen je novi odnosno unaprijeđeni algoritam evidencijskog zaključivanja [113], [104], [121]. Novi pristup u evidencijskom zaključivanju trebao bi ispuniti navedene aksiome za sintezu i pružiti pouzdanu agregaciju potpunih i

nepotpunih informacija koristeći novu težinsku normizaciju prikazanu sljedećim izrazom:

$$\sum_{i=1}^L \omega_i = 1, \quad (5.1)$$

koji zadovoljava aksiom konzensusa. Kod novog algoritma evidencijskog zaključivanja ostatak težinske vjerojatnosti tretirat će se posebno s obzirom na relativne težine atributa i nepotpunost procijene. Koncept mjerenja stupnja uvjerenja i mjerenja pouzdanosti u Dempster-Shafer [42], [59], [84] teoriji zaključivanja mogu se iskoristiti za odabiranje gornjih i donjih vrijednosti stupnjeva uvjerenja. U poboljšanom algoritmu evidencijskog zaključivanja $m_{H,i}$, prikazan u izrazu (4.6), rastavljen je na dva dijela.

$$\bar{m}_{H,i} = 1 - \omega_i \quad (5.2)$$

$$\tilde{m}_{H,i} = \omega_i \left(1 - \sum_{i=1}^N \beta_{n,i} \right) \quad (5.3)$$

također vrijedi i

$$\bar{m}_{H,i} + \tilde{m}_{H,i} = m_{H,i}. \quad (5.4)$$

Prvi dio $\bar{m}_{H,i}$ je linearna funkcija od ω_i i ovisi o težini i -tog atributa. Ukoliko težina osnovnog atribut e_i iznosi nula ili je $\omega_i = 0$, tada će i $\bar{m}_{H,i}$ imati vrijednost 1. U suprotnom ukoliko osnovni atribut e_i dominira procjenom ili je $\omega_i = 1$ tada će $\bar{m}_{H,i}$ imati vrijednost 0. Jednostavno rečeno $\bar{m}_{H,i}$ predstavlja stupanj kojim ostali atributi sudjeluju u procjeni.

Drugi dio ostatka težinske vjerojatnosti koji nije dodijeljen niti jednoj ocjeni je $\tilde{m}_{H,i}$ i on je posljedica nepotpunosti procjene osnovnih atributa $S(e_i)$. Ako je procjena osnovnog atributa $S(e_i)$ potpuna tada $\tilde{m}_{H,i}$ iznosi nula, u suprotnom $S(e_i)$ je nepotpuna i $\tilde{m}_{H,i}$ će imati vrijednost proporcionalnu ω_i i biti će između 0 i 1.

Pretpostavimo da $m_{n,I(i)}$ ($n = 1, \dots, N$), $\tilde{m}_{H,I(i)}$ i $\bar{m}_{H,I(i)}$ predstavljaju kombinirane težinske vjerojatnosti nastale agregacijom prvih i procjena. Tada možemo prikazati novi algoritam evidencijskog zaključivanja kao rekurziju, koja za $(i+1)$ procjenu uzima u obzir prvih i procjena, sljedećim izrazom:

$$m_{n,I(i+1)} = K_{I(i+1)} \left[m_{n,I(i)} m_{n,i+1} + m_{H,I(i)} m_{n,i+1} + m_{n,I(i)} m_{H,i+1} \right] \quad (5.5)$$

$$m_{H,I(i)} = \tilde{m}_{H,I(i)} + \bar{m}_{H,I(i)} \quad (5.6)$$

$$\tilde{m}_{H,I(i+1)} = K_{I(i+1)} [\tilde{m}_{H,I(i)} \tilde{m}_{H,i+1} + \bar{m}_{H,I(i)} \tilde{m}_{H,i+1} + \tilde{m}_{H,I(i)} \bar{m}_{H,i+1}] \quad (5.7)$$

$$\bar{m}_{H,I(i+1)} = K_{I(i+1)} [\bar{m}_{H,I(i)} \bar{m}_{H,i+1}] \quad (5.8)$$

$$K_{I(i+1)} = \left[1 - \sum_{t=1}^N \sum_{\substack{j=1 \\ j \neq t}}^N m_{t,I(i)} m_{j,i+1} \right]^{-1} \quad i = \{1, \dots, L-1\}. \quad (5.9)$$

Nakon što su obavljene sve L procjene, kombinirani stupanj uvjerenja možemo izračunati uz uporabu normizacijskog procesa danog sljedećim izrazima:

$$\beta_n = \frac{m_{n,I(L)}}{1 - \bar{m}_{H,I(L)}} \quad n = 1, \dots, N \quad (5.10)$$

$$\beta_H = \frac{\tilde{m}_{H,I(L)}}{1 - \bar{m}_{H,I(L)}} \quad (5.11)$$

Kao što je prikazano izrazima (5.10) i (5.11) β_n je stupanj uvjerenja za ocjenu H_n koja je dodijeljena procjenom, dok je β_H nedodijeljeni stupanj uvjerenja i predstavlja nepotpunost u ukupnom procesu procjene. Moguće je dokazati da na ovaj način dobiveni kombinirani stupnjevi uvjerenja zadovoljavaju sva četiri aksioma sinteze.

5.2. Očekivana konačna ocjena stanja objekta

Ukoliko na ovaj način dobivene ocjene stanja objekata nisu dovoljno jasne da bi se istaknula razlika u procjenama više različitih objekata ili više različitih stanja istog objekta uvodimo pojam očekivane konačne ocjene da bi njime prikazali ekvivalentnu numeričku vrijednost pojedinih ocjena dobivenih procesom agregacije.

Pretpostavimo da je $u(H_n)$ očekivana konačna ocjena procjene H_n s tim da je $u(H_{n+1}) > u(H_n)$, gdje je H_{n+1} poželjnija odnosno bolja ocjena od H_n . Očekivana konačna ocjena $u(H_n)$ može biti izračunata uz uporabu metode dodjeljivanja vjerojatnosti [10], [17] ili korištenjem regresijskog modela s parcijalnim ocjenama ili usporedbama. Ukoliko su procjene potpune ($\beta_H = 0$) očekivana konačna ocjena općeg atributa y može se izračunati uz pomoć sljedećeg izraza:

$$u(y) = \sum_{n=1}^N \beta_n u(H_n). \quad (5.12)$$

Stanje objekta predstavljeno ocjenom a je poželjnije stanje od stanja objekta predstavljenog ocjenom b ukoliko je očekivana konačna ocjena a veća od očekivane konačne ocjene b odnosno $u(y(a)) > u(y(b))$. Stupanj uvjerenja β_n dan u izrazu (5.10), upućuje na donju granicu procjene na koju možemo procijeniti opći atribut y . Gornja granica procjene dana je mjerom plauzibilnosti za H_n ili točnije $(\beta_n + \beta_H)$. Raspon ocjena na koje može biti procijenjen opći atribut y dan je intervalom $[\beta_n, (\beta_n + \beta_H)]$. Ukoliko je procjena promatranog objekta potpuna tada će se interval reducirati samo na vrijednost β_n , drugim riječima interval stupnjeva uvjerenja je ovisan o nedodijeljenom stupnju uvjerenja β_H . U svakom drugom slučaju se vrijednost na koju se opći atribut y može procijeniti nalazi u intervalu od β_n do $(\beta_n + \beta_H)$. Sukladno iznesenom moguće je definirati tri vrijednosti koje jednoznačno karakteriziraju procjenu općeg atributa y , najveća, najmanja i srednja vrijednost očekivane konačne ocjene koje su dane sljedećim izrazima:

$$u_{\max}(y) = \sum_{n=1}^{N-1} \beta_n u(H_n) + (\beta_N + \beta_H) u(H_N) \quad (5.13)$$

$$u_{\min}(y) = (\beta_1 + \beta_H) u(H_1) + \sum_{n=2}^N \beta_n u(H_n) \quad (5.14)$$

$$u_{\text{avg}}(y) = \frac{u_{\max}(y) - u_{\min}(y)}{2}. \quad (5.15)$$

Ukoliko su sve procjene atributa y potpune, odnosno za $\beta_H = 0$ vrijedi da je $u(y) = u_{\max}(y) = u_{\min}(y) = u_{\text{avg}}(y)$.

Uspoređivanje stanja dvaju objekata a_l i a_k zasnovano je na njihovim konačnim ocjenama i odgovarajućim intervalima. Kažemo da je stanje koje ima objekt a_l poželjnije odnosno bolje od stanja objekta a_k onda i samo onda ako je $u_{\min}(y(a_l)) > u_{\max}(y(a_k))$. Dva objekta su jednakog stanja ako i samo ako su $u_{\min}(y(a_l)) = u_{\min}(y(a_k))$ i $u_{\max}(y(a_l)) = u_{\max}(y(a_k))$. U svakom drugom slučaju uspoređivanje stanja dvaju promatranih objekata je nepotpuno i nepouzdan. Da bi povećali pouzdanost usporedbe dvaju ili više objekata nužno je povećati kvalitetu prvobitnih procjena na način da se smanji nepotpunost u procjenama atributa za stanja objekta a_l i a_k .

Sažeto rečeno poboljšani algoritam evidencijskog zaključivanja sastoji se od prikupljanja i interpretacije informacija (4.3). Izrazom (5.1) koristimo se pri normizaciji težinskih vrijednosti, dok uz pomoć izraza (4.5), (4.6), (5.2) i (5.3) određujemo osnovne vjerojatnosti. Za proces agregacije atributa koristimo izraze od (5.5) do (5.9). Da bi dobili kombinirane stupnjeve uvjerenja nužno je koristiti izraze (5.10) i (5.11). I konačno da bi bilo moguće napraviti usporedbu stanja dva ili više objekata služimo se izrazima od (5.13) do (5.15).

U sljedećem poglavlju bit će prikazane moguće metode za obradu i interpretaciju prikupljenih informacija o stanju sustava, a nakon toga slijede konkretni primjeri uporabe poboljšanog algoritma evidencijskog zaključivanja za procjenu stanja jedne trafostanice i za procjenu stanja segmenta sustava za prijenos električne energije.

6. ANALIZA ULAZNIH PODATAKA


Prije prikaza poboljšanog algoritma evidencijskog zaključivanja na konkretnom primjeru procjene stanja tehničkog sustava potrebno je reći nešto više o načinu pripreme ulaznih podataka za agregacijski proces. Riječ je o analizi, obradi i interpretaciji podataka do kojih se dolazi mjerenjem ili neposrednom procjenom. Da bi se takvi podaci mogli koristiti potrebno ih je na adekvatan način obraditi i transformirati, najčešće iz kvantitativne domene u kvalitativnu, tako da zadovoljavaju izraze (4.2) i (4.3) kojima je definiran ulaz u agregacijski proces [15], [27], [98], [100], [114]. Metode koje se ovom prilikom koriste ovise o prirodi informacije i procjeniteljevom poznavanju tehničkog sustava. Biti će predstavljene tri osnovne metode no bitno je istaknuti da odabir metoda i formiranje ocjena prema izrazu (4.3) uvelike ovise o samom tehničkom postrojenju, njegovoj vrsti i namjeni te da se način formiranja ocjena može razlikovati od jedne tehničke grane do druge (npr. kemijska i prehrambena industrija ili proizvodnja električne energije) [36], [44], [45], [46].

6.1. Kontinuirana varijabla kao ulazni podatak

Pretpostavimo da stanje neke komponente sustava ocjenjujemo na osnovu mjerenja veličine x koja može poprimiti kontinuirane vrijednosti (npr. vrijeme uklopa prekidača, udio vlage u transformatorskom ulju i sl.). Zbog različitih faktora u mjernom postupku više uzastopnih mjerenja međusobno će se razlikovati. Mjerni rezultati ponašat će se prema njima svojstvenoj statističkoj razdiobi. Za većinu tehničkih sustava razdioba će se moći aproksimirati normalnom ili Gaussovom razdiobom sa parametrima \bar{x} i σ^2 (srednja vrijednost i standardna devijacija). Postavlja se pitanje kojim postupkom izmjerenu vrijednost transformirati u kvalitativnu ocjenu [15], [47], [48].

Prema preporuci proizvođača i iskustvu korisnika, promatrane komponente mogu se razvrstati u dobre ili loše tj. u razrede kojima možemo pridružiti kvalitativne ocjene. Razredi se definiraju rasponima mjerene veličine. Naravno, granice između razreda ne mogu biti precizno definirane tako da nužno dolazi do preklapanja ocjena. Umjesto definiranja čvrstih granica intervala za svaki se razred pojedinačno određuje srednja

vrijednost i devijacija mjerne veličine. Slika 6.1. prikazuje podjelu intervala promatrane varijable u nekoliko kvalitativnih razreda.



Slika 6.1. Podjela intervala mjerne veličine x u pet kvalitativnih razreda s pridruženim vjerojatnostima b_n

Dakle, svakom razredu $n = 1, \dots, N$ pridružujemo ocjenu H_n , srednju vrijednost \bar{x}_n i devijaciju σ_n^2 . Parametri \bar{x}_n i σ_n^2 procjenjuju se na različite načine ovisno o vrsti mjerene veličine, vrsti uređaja, preporuci proizvođača, statistici kvarova i iskustvu procjenitelja.


Za danu izmjerenu vrijednost x promatranoj komponenti pridružujemo kvalitativnu ocjenu H_n s određenom razinom pouzdanosti β_n . Stupanj uvjerenja ocjene β_n definira Gaussova razdioba s parametrima \bar{x}_n i σ_n^2 :

$$\beta_n \sim b_n = \frac{1}{\sigma_n \sqrt{2\pi}} e^{-\frac{(x-\bar{x}_n)^2}{2\sigma_n^2}} \quad (6.1)$$

Razumno je za pretpostaviti da je mjerenje fizikalnih veličina egzaktan postupak te da ne postoji neodređenost rezultata. Zbog toga sumu svih vjerojatnost β_n normiramo na vrijednost 1 :

$$\sum_{n=1}^N \beta_n = 1 \quad (6.2)$$

$$\beta_n = \frac{b_n}{\sum_{n=1}^N b_n} \quad (6.3)$$



Slika 6.2. Normirane razine pouzdanosti pojedinih ocjena

Normalna razdioba pretpostavlja određenu vjerojatnost za svaku vrijednost mjerenja, pa bi tako i svaka ocjena imala određenu vjerojatnost. Radi jednostavnosti možemo zanemariti ocjene kod kojih je vjerojatnost manja od određene vrijednosti (npr. 0.05).


Slike 6.1. i 6.2. odnose se na konkretan primjer ocjenjivanja transformatorskog ulja na osnovu mjerenja količine vlage. Varijabla x je udio vlage u ulju izražen u ppm.

Sličan grafikon dobije se za sve atribute kod kojih je kvalitativna ocjena razmjerna mjernom rezultatu (udio plina u ulju, temperatura spojeva, opterećenje, vrijeme isklopa prekidača itd.).

Za atribute kod kojih se mjeri odstupanje od određene idealne vrijednosti, a koje može biti i pozitivno i negativno, kvalitativna ocjena je razmjerna apsolutnoj vrijednosti razlike idealne i mjerene vrijednosti.

Tipičan primjer za takav slučaj je mjerenje sinkroniziranosti polova trolnog prekidača što je prikazano na Slici 6.3. Idealno vrijeme kašnjenja isklopa druga dva pola za prvim je $t_0 = 7$ ms. Maksimalno odstupanje od ovog vremena je $\Delta t = 2$ ms. Varijabla koju promatramo i ocjenjujemo je dakle apsolutna vrijednost izmjerenog vremena t i idealnog t_0 :

$$\Delta t = |t - t_0| \quad (6.4)$$



Slika 6.3. Ocjenjivanje sinkroniziranosti prekidača

6.2. Vrijeme eksploatacije kao ulazni podatak

Kada ocjenjujemo komponentu sustava na osnovu njene starosti polazimo od funkcije pouzdanosti u vremenu $R(t)$. Za određivanje ove funkcije potrebno je poznavati statistiku kvarova takve ili slične komponente. Karakterističan parametar je intenzitet kvara $\lambda(t)$ tj. vjerojatnost da će se komponenta pokvariti u danom trenutku t .

Funkciju pouzdanosti možemo opisati eksponencijalnom funkcijom vremena i intenziteta kvara

$$R(t) = e^{-\int_0^t \lambda dt} \quad (6.5)$$

U praksi je intenzitet kvara konstantan tijekom većine vremena eksploatacije komponente i često se izražava kao srednje vrijeme do kvara (Mean Time To Failure)

$$MTTF = \frac{1}{\lambda} \quad (6.6)$$

Ako je λ konstantan funkcija pouzdanosti glasi

$$R(t) = e^{-\lambda t} \quad (6.7)$$

Interval pouzdanosti $R(t) \in [0,1]$ tada se može podijeliti u N intervala kojima pridružujemo kvalitativne ocjene H_n , $n = 1, \dots, N$. Ova podjela može biti uniformna kao na Slici 6.4. ili drugačija sukladno odluci eksperta. Slika 6.4. prikazuje komponentu koja ima srednje vrijeme do kvara $MTTF = 12$ mjeseci. Na apscisi je predstavljena starost komponente u mjesecima.


Aritmetičku sredinu R_n svakog razreda preslikavamo na vremensku os

$$R_n = e^{-\lambda t_n} \quad (6.8)$$

$$t_n = -\frac{1}{\lambda} \ln R_n \quad (6.9)$$

Za poznatu starost t , komponenti pridružujemo kvalitativne ocjene H_n . Stupanj uvjerenja ocjene je veća što je vrijeme t bliže sredini intervala t_n . Zbog toga svakom intervalu $n = 1, \dots, N$ pridružujemo normalnu razdiobu s očekivanjem $\mu_n = t_n$:

$$b_n = \frac{1}{\sigma_n \sqrt{2\pi}} e^{-\frac{(t-t_n)^2}{2\sigma_n^2}} \quad (6.10)$$



Slika 6.4. Ocjenjivanje komponente Poissonovom distribucijom kvarova na osnovu starosti komponente.

Standardnu devijaciju σ_n odabiremo tako da su ispunjeni slijedeći uvjeti:


$$b_n(t_n) = R_n \quad (6.11)$$

$$\sigma_n = \frac{1}{R_n \sqrt{2\pi}} \quad (6.12)$$

Kao i u prethodnoj metodi ukupni stupanj uvjerenja svih ocjena normiramo prema jednadžbi

$$\beta_n = \frac{b_n}{\sum_{n=1}^N b_n} \cdot (1 - \beta_H) \quad (6.13)$$

gdje je β_H stupanj neodređenosti mjerenja. Ova neodređenost može nastati zbog nepoznavanja različitih faktora kao što su točna starost komponente ili točan iznos intenziteta kvara takvih uređaja. Na Slici 6.5. prikazane su pouzdanost svake od pet ocjena normirane na 100 % za rastavljač čije je srednje vrijeme do kvara $MTTF = 12$ mjeseci.



Slika 6.5. Vrijednosti pouzdanosti ocjena normirane na 100 % za rastavljač sa srednjim vremenom kvara $MTTF = 12$ mjeseci

6.3. Diskretna varijabla kao ulazni podatak

Općenito, diskretna varijabla x može poprimiti konačan broj vrijednosti K :

$$x \in \{x_k; k = 1, 2, \dots, K\} \quad (6.14)$$

x_k može biti:

- konkretna brojčana vrijednost (npr. broj prorada odvodnika prenapona)
- jedno od stanja iz konačnog skupa stanja (npr. stanje Buchholz releja: A - ispravno, B - upozorenje i C – isključenje)
- deskriptivna veličina (npr. dobar, loš, osrednji).

U većini slučajeva broj vrijednosti K nije velik, tj. aproksimativno ne prelazi deset. Za veći broj vrijednosti mogu se koristiti ranije navedene metode za kontinuirane varijable. Svakoj vrijednosti x_k pridružuje se skup kvalitativnih ocjena s odgovarajućim stupnjem uvjerenja:

$$x_k \rightarrow (H_n, \beta_n)_k \quad n = 1, 2, \dots, N \quad (6.15)$$

Pridjeljivanje ocjena praktično se najjednostavnije može ostvariti formiranjem pregledne tablice (eng. *lookup table*):

Tablica 6.1. Transformacijska tablica za pretvorbu diskretnih stanja u kvalitativne ocjene

stanje\ocjena	H_1	H_2	...	H_n		H_N
x_1	β_{11}	β_{21}	...	β_{n1}	...	β_{N1}
x_2	β_{12}	β_{22}	...	β_{n2}	...	β_{N2}
...
x_k	β_{1k}	β_{2k}		β_{nk}	...	β_{Nk}
...
x_K	β_{1K}	β_{2K}	...	β_{nK}	...	β_{NK}

U praksi se svakom stanju pridjeljuje uglavnom samo jedna ili dvije ocjene, tako da će većina elemenata tablice biti jednaka nuli.

Iz sume stupnjeva uvjerenja svih ocjena za jedno stanje izračunava se stupanj neodređenosti svakog stanja:

$$\beta_{Hk} = 1 - \sum_{n=1}^N \beta_{nk} \quad (6.16)$$

Koeficijente β_{nk} određuje ekspert ili grupa eksperata za određenu vrstu komponenti sustava. Metode određivanja uglavnom su temeljene na iskustvenim pravilima koja se definiraju za svaki slučaj posebno [48], [53], [74], [43], [114].

Promotrimo primjer Buchholz releja:

Buchholz relej je komponenta čije stanje (pogotovo C – isključenje) jako (u negativnom smislu) utječe na ukupnu ocjenu transformatora. Kada je Buchholz relej u stanju C – isključenje, transformator i pripadni dijelovi postrojenja su isključeni, te bi ocjena promatranog objekta trebala biti strogo negativna, prema Tablici 6.2 $\beta_{I3} = 1$.

U normalnom pogonu relej je u stanju A – ispravno. Ovo stanje je neutralno tj. ne daje neku posebnu informaciju o stanju transformatora, pa ocjena ne bi trebala imati velikog utjecaja na ukupnu ocjenu. Budući da težinu promatranog objekta ne možemo smanjivati, stanju A pridjeljujemo srednju ocjenu.

Relej može biti u kvaru pa pokazuje stanje A – ispravno premda se desio kvar. Zbog toga srednjoj ocjeni pridjeljujemo stupanj uvjerenja oko 70 %.

Stanje B – upozorenje relej pokazuje ako se desio kvar ili je samo pala razina ulja. Ovakvo stanje uglavnom zahtjeva intervenciju pa dodjeljujemo relativno loše ocjene s stupnjevima uvjerenja $\beta_{I2}=0,4$ i $\beta_{22}=0,3$. Zbog mogućnosti kvara samog releja nesigurnost te ocjene je $\beta_{H2}=0,3$. Stupnjevi uvjerenja β_n dani su u Tablici 6.2.

Tablica 6.2. Ocjenjivanje transformatora na osnovu stanja Buchholz releja

Stanje\ocjena	Nedovoljno	Dostatno	Prosječno	Vrlo dobro	Izvršno	Nesigurnost
A – ispravno	0	0	0,7	0	0	0,3
B – upozorenje	0,4	0,3	0	0	0	0,3
C – isključenje	1,0	0	0	0	0	0

Dodijeljene kvalitativne ocjene i pripadajući stupnjevi uvjerenja dani su u Tablici 6.2.


Drugi primjer je procjena odvodnika prenapona na osnovu broja prorada. Promatrana varijabla je broj prorada koji teorijski može biti jako velik:

$$x \in \{0, 1, 2, \dots\}, \quad (6.17)$$

ali na osnovu praktičnog iskustva može se dati gruba procjena prosječne vrijednosti od 0,1 prorada po odvodniku na godini. Za vrijeme svoga životnog vijeka koji je u praksi

između 15 i 20 godina odvodnik proradi prosječno 2 puta. Napomenimo da se broje prorade koje registrira brojač prorada, a to su prenaponi veće energije koji mogu imati utjecaja na strukturu tijela odvodnika. Tendencija je kod suvremenijih brojača prorada postići rangiranje prenapona prema jačini strujnog impulsa, što je bitno za ocjenu stanja odvodnika.

Zbog malog skupa vrijednosti x ovaj atribut ne možemo statistički promatrati kao u prethodno opisanim metodama, već koristimo transformacijsku tablicu koju u ovom primjeru možemo prikazati i grafički uz pomoć slike 6.6. Pretpostavljena je pouzdanost brojača prorada $1 - \beta_H = 0,8$.



Slika 6.6. Ocjenjivanje odvodnika prenapona na osnovu broja prorada.

Ocjena stanja obrnuto je proporcionalna broju prorada, ali uzimamo u obzir da je neka od zabilježenih prorada mogla biti energetski niska te da nije utjecala na stanje odvodnika. Neodređenost ocjene β_H ovisi o pouzdanosti samog brojača prorada što ovisi o modelu i konstrukciji samog odvodnika prenapona.

Na osnovu iznesenih primjera vidljivo je da su metode za pripremu prikupljenih kvantitativnih ili kvalitativnih podataka prilično složene. Različiti tipovi podataka zahtijevaju različite tehnike i pristupe transformaciji gdje do izražaja dolaze praktična iskustva i znanja eksperta [49], [51], [53]. Tek kada su prikupljene i na odgovarajući način predstavljene informacije o stanju osnovnih atributa jednog ili više promatranih objekata možemo prijeći na slijedeći korak odnosno na procjenu stanja općih atributa i u konačnici na procjenu stanja cijelog objekta ili sustava. U slijedećem poglavlju detaljno je opisana procjena stanja jednog složenog tehničkog sustava odnosno energetskog

transformatora, a u poglavlju pod brojem 8. detaljno je opisan algoritam pogodan za predviđanje stanja na osnovu malog broja uzoraka i prikazan je primjer predviđanja stanja zasnovan na postojećim podacima kromatografske analize.

7. DEKOMPOZICIJSKI MODEL I PROCJENA STANJA TRANSFORMATORA

Da bi bilo moguće dati ocjenu stanja složenog tehničkog sustava kao što je energetski transformator, potrebno je prikupiti, obraditi i interpretirati veliku količinu kvalitativnih i kvantitativnih informacija [17], [19], [28], [46], [98], [114], [105], [109]. Do potrebnih informacija dolazi se mjerenjem i procjenom na samom promatranom objektu ili uz pomoć daljinskog nadgledanja i stalnog prikupljanja informacija [36], [60], [63]. Neovisno o načinu na koji se informacije prikupljaju potrebno ih je prebaciti u kvalitativnu domenu uz pomoć odgovarajućeg semantičkog aparata i metoda opisanih u prethodnom poglavlju. Pretpostavimo da su informacije uspješno prikupljene i prevedene u odgovarajuću kvalitativnu domenu i da su atributi iz izraza (4.1) uspješno procijenjeni na skup ocjena definiran izrazom (4.2), te da su procjene atributa dane sukladno izrazu (4.3).

Uzimajući u obzir sve navedeno, neki opći atribut ili opće svojstvo, možemo procijeniti na osnovu osnovnih atributa direktno ili preko atributa nižeg reda u ovisnosti o dekompozicijskom modelu koji koristimo. Na primjer, stanje tekuće odnosno krute izolacije energetskog transformatora može se odrediti provođenjem kromatografske analize te mjerenjem fizikalnih i električnih veličana. Kromatografskom analizom određuje se udio karakterističnih plinova otopljenih u ulju (vodik, metan, acetilen, etilen i dr.), mjerenjem fizikalnih veličana utvrđuje se vlaga u ulju, papirnoj izolaciji, granična površinska napetost, temperatura ulja, i sl., dok se mjerenjem električnih veličina utvrđuje otpor izolacije, faktor dielektričnih gubitaka, probojna čvrstoća ulja i druge veličine kao što je prikazano na slikama 4.2., 7.1. i 7.2.. Iz slike 7.1. vidljiv je višerazinski dekompozicijski model za energetski transformator. Slika 7.2. prikazuje dekompoziciju jednog atributa druge razine tj. prikazuje dekompoziciju za tekuću krutu izolaciju. Vidljivo je nekoliko razina atributa u podjeli od općenitog do osnovnog atributa. Svaki atribut e_i iz skupa osnovnih atributa E , treba imati definiranu težinu ω_i , i stupanj uvjerenja β_i u ocjenu H_m .

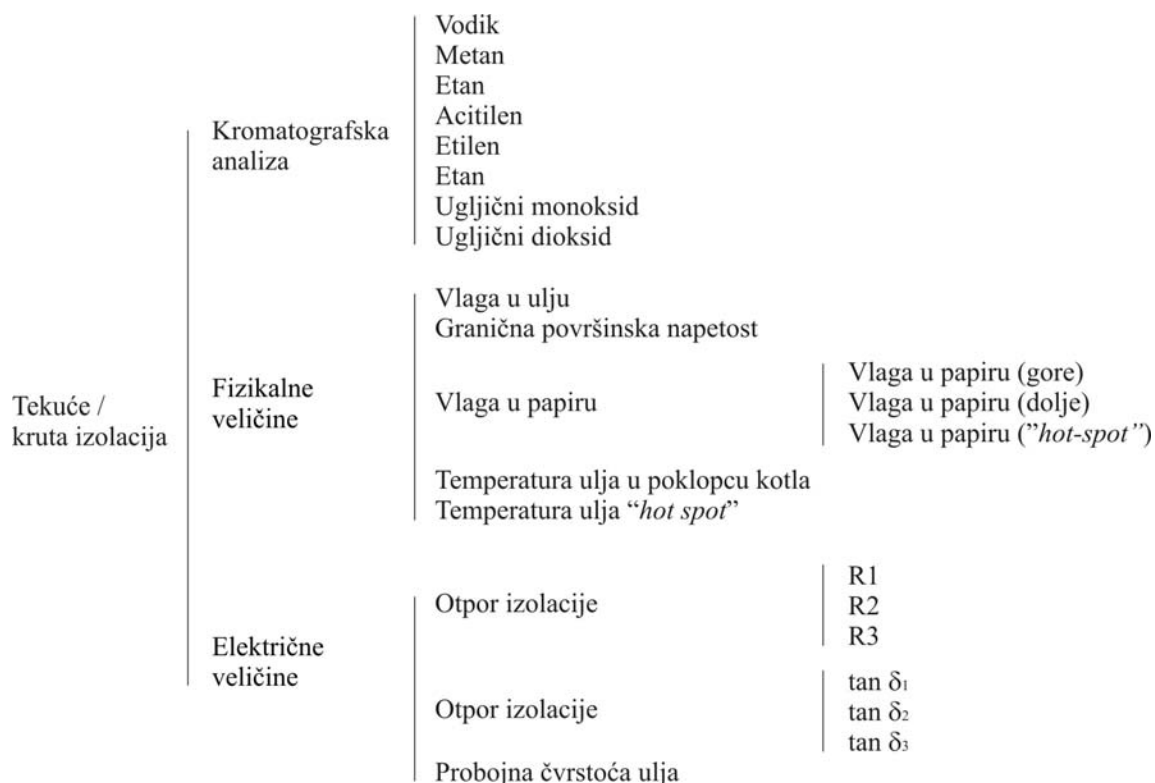
U ovom radu kao primjer dokazivanja zamisli postupka (eng. *Proof of Concept, PoC*) za tehnički sustav odabran je energetski transformator [91], [40], [83], [92], [105], [122] te

je za isti izrađen dekompozicijski model, s odgovarajućim općim i osnovnim atributima. Svim atributima e_i promatranog modela pridružene su težine ω_i . Kao osnovni atributi odabrane su veličine za koje se mogu provesti odgovarajuća mjerenja ili dati procjene te odrediti stupanj uvjerenja β_i u odgovarajuću ocjenu H_n . Kako je riječ o izuzetno složenom tehničkom sustavu koji se sastoji od niza podsustava određivanje dekompozicijskog modela nije jednostavan zadatak. Izradom dekompozicijskog modela nastojalo se energetske transformator rastaviti na što više neovisnih osnovnih elemenata sustava u čije je stanje moguće dobiti uvid mjerenjem ili procjenom. Elementi sustava u dekompozicijskom modelu nazivaju se atributi sustava (4.1), te će se u daljnjem tekstu termin atribut sustava odnositi na element dekomponiranog sustava.

Energetski transformator	Opći izvedeni atributi	
	Namoti	
	Tekuće / kruta izolacija	
	Kotao	
	Provodnici	
	Regulacijska sklopka	
	Rashladni sustav	

Slika 7.1. Osnovna dekompozicija energetskog transformatora

Predloženi dekompozicijski model energetskog transformatora prikazan je na slici 7.3. Vidljiva je podjela na sedam općih atributa koji u principu predstavljaju određene dijelove promatranog tehničkog sustava te pružaju uvid u opće izvedene attribute, stanje namota, stanje tekuće krute izolacije, stanje kotla, stanje provodnika, stanje regulacijske prekolopke i stanje rashladnog sustava. Svaki od navedenih sedam općih atributa dijeli se na attribute nižeg reda sve do osnovnih atributa. Tako je, na primjer, stanje namota predstavljeno s četiri opća atributa tj. stanjem kapaciteta namota, strujom magnetiziranja, djelatnim otporom namota i kontrolom pomaka namota, a svaki od četiri navedena opća atributa predstavljen je sa određenim brojem osnovnih atributa. U slučaju npr. kapaciteta namota, osnovni atributi su tri mjerljive veličine izražene u pF tj. C_1 , C_2 i C_3 koje predstavljaju kapacitet namata mjeren pri različitim mjernim spojevima. Slična podjela vidljiva je i za sve ostale attribute. Model prikazan na slici 7.3. sastoji se od 91 osnovna atributa od kojih je za 45 moguće pratiti uz pomoć ugrađenog sustava za daljinski nadzor, a za 46 atributa potrebno je izvršiti mjerenje ili procjenu na promatranom objektu.



Slika 7.2. Dekompozicija tekuće krute izolacije

7.1. Osnovni atributi

Dekompozicijski model prikazan je u Prilogu 1. na slici 7.3. i sastoji se od pet razina. Na prvoj i osnovnoj razini predstavljeno je ukupno stanje promatranog objekta tj. energetskog transformatora, na drugoj razini nalazi se sedam općih atributa koji pružaju uvid u opće stanje, stanje namota, stanje tekuće odnosno krute izolacije, stanje kotla, stanje provodnika, stanje regulacijske preklopke i stanje rashladnog sustava. Na trećem nivou nalaze se opći atributi koji predstavljaju detaljniju razradu općih atributa drugog nivoa i određen broj osnovnih atributa. Četvrti nivo sadrži pretežno osnovne attribute i manji broj općih atributa koji su na petom nivou predstavljeni svojim osnovnim atributima. Ukratko predloženi model sastoji se od 91 osnovnog atributa koji za koje postoje podaci iz sustava za udaljeni nadzor, mogu se provesti odgovarajuća mjerenja, ili dati procjene stanja. U Tablici 7.1. nalazi se popis, s kratkim opisom, svih osnovnih atributa predloženih ovim modelom. Također, naznačene su mjerne jedinice i način prikupljanja podataka tj. da li su podaci prikupljeni mjerenjem i pregledom sustava

(*offline* podaci, u Tablici 7.1. označeni s Tip 1.) ili potječu iz sustava za udaljeni nadzor i prikupljanje podataka (*online* podaci, u Tablici 7.1. označeni sa Tip 2.)

Tablica 7.1. Osnovni atributi dekompozicijskog modela energetskog transformatora

Rb	Naziv osnovnog atributa	Opis	Mjerna jedinica	Način prikupljanja	
1.	Opterećenje			Tip 2	
2.	Preostali životni vijek		god.	Tip 2	
3.	Brzina starenja			Tip 2	
4.	C1 ((VN+SN):STN)	Kapacitet namota u mjernom spoju (VN+SN):STN)	pF	Tip 1	
5.	C2 (VN:M)	Kapacitet namota u mjernom spoju (VN:M)	pF	Tip 1	
6.	C3 (STN:M)	Kapacitet namota u mjernom spoju (STN:M)	pF	Tip 1	
7.	I1 (VN Faza U)	Struja magnetiziranja za VN Faza U	mA	Tip 1	
8.	I2 (VN Faza V)	Struja magnetiziranja za VN Faza V	mA	Tip 1	
9.	I3 (VN Faza W)	Struja magnetiziranja za VN Faza W	mA	Tip 1	
10.	I4 (SN Faza U)	Struja magnetiziranja za SN Faza U	mA	Tip 1	
11.	I5 (SN Faza V)	Struja magnetiziranja za SN Faza V	mA	Tip 1	
12.	I6 (SN Faza W)	Struja magnetiziranja za SN Faza W	mA	Tip 1	
13.	R1 (VN: 1U – N)	Djelatni otpor namota između VN: 1U-N	R/Ω	Tip 1	
14.	R2 (VN: 1V – N)	Djelatni otpor namota između VN: 1V-N	R/Ω	Tip 1	
15.	R3 (VN: 1W – N)	Djelatni otpor namota između VN: 1W-N	R/Ω	Tip 1	
16.	R4 (SN: 2U – N)	Djelatni otpor namota između SN: 2U-N	R/mΩ	Tip 1	
17.	R5 (SN: 2V – N)	Djelatni otpor namota između SN: 2V-N	R/mΩ	Tip 1	
18.	R6 (SN: 2W – N)	Djelatni otpor namota između SN: 2W-N	R/mΩ	Tip 1	
19.	R7 (STN: 3U1 – 3W2)	Djelatni otpor namota između STN: 3U1-3W2	R/mΩ	Tip 1	
20.	Asimetrija Lx1	Rasipni induktivitet parova namota pri položaju reg. 1	%	Tip 1	
21.	Asimetrija Lx13b	Rasipni induktivitet parova namota pri položaju reg. 13b	%	Tip 1	
22.	Asimetrija Lx25	Rasipni induktivitet parova namota pri položaju reg. 25	%	Tip 1	
23.	Vodik	Koncentracija plinova otopljenih u transformatorskom ulju	μl/l (ppm)	Tip 2	Tip 1
24.	Metan	Koncentracija plinova otopljenih u transformatorskom ulju	μl/l (ppm)	Tip 2	Tip 1

25.	Acitilen	Koncentracija plinova otopljenih u transformatorskom ulju	μl/l (ppm)	Tip 2	Tip 1
26.	Etilen	Koncentracija plinova otopljenih u transformatorskom ulju	μl/l (ppm)	Tip 2	Tip 1
27.	Etan	Koncentracija plinova otopljenih u transformatorskom ulju	μl/l (ppm)	Tip 2	Tip 1
28.	Ugljični monoksid	Koncentracija plinova otopljenih u transformatorskom ulju	μl/l (ppm)	Tip 2	Tip 1
29.	Ugljični dioksid	Koncentracija plinova otopljenih u transformatorskom ulju	μl/l (ppm)	Tip 2	Tip 1
30.	Vlaga u ulju	Koncentracija vode u transformatorskom ulju	mg/kg	Tip 2	Tip 1
31.	Granična površinska napetost	Granična površinska napetost na 20°C	mN/m (na 20°C)		Tip 1
32.	Vlaga u papiru (gore)		%	Tip 2	
33.	Vlaga u papiru (dolje)		%	Tip 2	
34.	Vlaga u papiru (hot-spot)		%	Tip 2	
35.	Temperatura ulja u poklopcu kotla		°C	Tip 2	
36.	Temperatura ulja hot-spot		°C	Tip 2	
37.	R1 ((VN+SN):STN)	Otpor izolacije namota i jezgre između (VN+SN):STN	GΩ (10min)		Tip 1
38.	R2 (VN:M)	Otpor izolacije namota i jezgre između VN:M	GΩ (10min)		Tip 1
39.	R3 (STN:M)	Otpor izolacije namota i jezgre između STN:M	GΩ (10min)		Tip 1
40.	tan δ1 ((VN+SN):STN)	Faktor dielektričnih gubitaka izolacije namota između (VN+SN):STN	%		Tip 1
41.	tan δ2 (VN:M)	Faktor dielektričnih gubitaka izolacije namota između VN:M	%		Tip 1
42.	tan δ3 (STN:M)	Faktor dielektričnih gubitaka izolacije namota između STN:M	%		Tip 1
43.	Probojna čvrstoća ulja	Fizikalno kemijska ispitivanja transformatorskog ulja	kV		Tip 1
44.	Sušionik zraka kotla				Tip 1
45.	Nivo ulja u kotlu				Tip 1
46.	Popuštanje brtvi				Tip 1
47.	tan δ1 (N)	Faktor dielektričnih gubitaka na provodnicima (N)	%		Tip 1
48.	tan δ2 (1U)	Faktor dielektričnih gubitaka na provodnicima (1U)	%		Tip 1
49.	tan δ3 (1V)	Faktor dielektričnih gubitaka na provodnicima (1V)	%		Tip 1
50.	tan δ4 (1W)	Faktor dielektričnih gubitaka na provodnicima (1W)	%		Tip 1
51.	tan δ5 (2U)	Faktor dielektričnih gubitaka na provodnicima (2U)	%		Tip 1

2.	tan δ_6 (2V)	Faktor dielektričnih gubitaka na provodnicima (2V)	%	<i>Tip 1</i>
53.	tan δ_7 (W)	Faktor dielektričnih gubitaka na provodnicima (2W)	%	<i>Tip 1</i>
54.	C1 (N)	Kapacitet izolacije provodnika (Nultočka)	pF	<i>Tip 1</i>
55.	C2 (1U)	Kapacitet izolacije provodnika (Faza)	pF	<i>Tip 1</i>
56.	C3 (1V)	Kapacitet izolacije provodnika (1V)	pF	<i>Tip 1</i>
57.	C4 (1W)	Kapacitet izolacije provodnika (1W)	pF	<i>Tip 1</i>
58.	C5 (2U)	Kapacitet izolacije provodnika (2U)	pF	<i>Tip 1</i>
59.	C6 (2V)	Kapacitet izolacije provodnika (2V)	pF	<i>Tip 1</i>
60.	C7 (2W)	Kapacitet izolacije provodnika (2W)	pF	<i>Tip 1</i>
61.	Termovizijsko snimanje provodnika			<i>Tip 2</i>
62.	Indeks promjene faza 1U	Indeks promjene kapaciteta provodnika primara (1U)		<i>Tip 2</i>
63.	Indeks promjene faza 1V	Indeks promjene kapaciteta provodnika primara (1V)		<i>Tip 2</i>
64.	Indeks promjene faza 1W	Indeks promjene kapaciteta provodnika primara (1W)		<i>Tip 2</i>
65.	Indeks promjene faza 2U	Indeks promjene kapaciteta provodnika sekundara (2U)		<i>Tip 2</i>
66.	Indeks promjene faza 2V	Indeks promjene kapaciteta provodnika sekundara (2V)		<i>Tip 2</i>
67.	Indeks promjene faza 2W	Indeks promjene kapaciteta provodnika sekundara (2W)		<i>Tip 2</i>
68.	Broj operacija sklopke			<i>Tip 2</i>
69.	Ukupna preključena struja		kA	<i>Tip 2</i>
70.	Snaga motora reg. sklopke		%	<i>Tip 2</i>
71.	Sušionik zraka kotla reg. sklopke			<i>Tip 1</i>
72.	Stanje pumpe 1			<i>Tip 2</i>
73.	Stanje pumpe 2			<i>Tip 2</i>
74.	Stanje pumpe 3			<i>Tip 2</i>
75.	Stanje pumpe 4			<i>Tip 2</i>
76.	Stanje pumpe 5			<i>Tip 2</i>
77.	Stanje ventilatora 1			<i>Tip 2</i>
78.	Stanje ventilatora 2			<i>Tip 2</i>
79.	Stanje ventilatora 3			<i>Tip 2</i>
80.	Stanje ventilatora 4			<i>Tip 2</i>
81.	Stanje ventilatora 5			<i>Tip 2</i>
82.	Stanje ventilatora 6			<i>Tip 2</i>

83.	Stanje ventilatora 7			Tip 2
84.	Stanje ventilatora 8			Tip 2
85.	Stanje ventilatora 9			Tip 2
86.	Stanje ventilatora 10			Tip 2
87.	Učinkovitost hladnjaka 1		%	Tip 2
88.	Učinkovitost hladnjaka 2		%	Tip 2
89.	Učinkovitost hladnjaka 3		%	Tip 2
90.	Učinkovitost hladnjaka 4		%	Tip 2
91.	Učinkovitost hladnjaka 5		%	Tip 2

Na osnovu prikupljenih kvantitativnih ocjena potrebno je odrediti kvalitativne ocjene za gore navedene osnovne atribute. Kvalitativne ocjene osnovnih atributa zajedno s težinama pojedinih osnovnih atributa predstavljaju ulaz u agregacijski proces na osnovu čega će se odrediti ocjene općih atributa nadređene razine. Ponavljanjem agregacijskog postupka do najviše razine određuje se ocjena stanja cijelog promatranog objekta. U slijedećem poglavlju slijedi opis postupka procjene stanja za energetske transformator.

7.2. Procjena stanja

Za procjenu stanja energetskog transformatora korišteni su realni podaci iz održavanja tvrtke HEP d.d., a odnose se na energetske transformator proizvođača Končar, tip 1 ARZ 300000-420/A. Podaci pokrivaju vremensko razdoblje od kolovoza 2005. g. do svibnja 2011.g. Općenito možemo reći da su podaci prikupljeni najmanje jednom (2009.g.) do najviše četiri puta godišnje (2010.g.) i da su prikupljeni u nepravilnim vremenskim intervalima iako se za određeni podskup podataka mogu pronaći i pravilni vremenski razmaci između prikupljenih podataka.

Od kolovoza 2005.g. pa do rujna 2009.g. postoje samo podaci dobiveni mjerenjem ili procjenom (*offline* podaci), a od veljače 2010.g. dostupni su i podaci dobiveni iz sustava za udaljeni nadzor (*online* podaci). Stoga možemo reći da prikupljeni podaci od kolovoza 2005.g. pa do svibnja 2011.g. variraju kako u količini prikupljenih podataka (broju osnovnih atributa za koji postoje dostupni podaci u određenom trenutku) tako i izvoru podataka (*offline* i/ili *online* prikupljeni podaci). Prikupljeni kvantitativni podaci, pravila pretvaranja i odgovarajuće kvalitativne vrijednosti prikazani su u Prilogu 3. u Tablici 7.2.

Nakon što su definirani dostupni podaci po vremenskim točkama moguće je sukladno smjernicama iz poglavlja šest transformirati postojeće kvantitativne podatke u kvalitativnu domenu odnosno prikupljenim podacima pridružiti odgovarajuće ocjene koje predstavljaju ocjenu pojedinog osnovnog atributa. Iz Tablice 7.2. vidljivi su i granični uvjeti za pretvorbu podataka, te je dan prikaz kvalitativnih ocjena za svaki osnovni atribut za koji postoje ulazni podaci. Procjena stanja određenog općeg atributa počinje tako da se nad stupnjevima uvjerenja u ocjene H_n njemu pripadajućih osnovnih atributa e_i , uz uvažavanje težina ω_i , provede agregacijski postupak kao što je to prikazano u izrazima od (5.5) do (5.12). Ocjena stanja promatranog općeg atributa predstavljena je tada distribucijom vjerojatnosti tj. stupnjevima uvjerenja u ocjene iz skupa H_n , kao što je to prikazano izrazom (5.12). Ukoliko želimo izvršiti usporedbu stanja između dvije ili više vremenske točke možemo se poslužiti izrazima od (5.13) do (5.15).

Svi izračuni potrebni za provođenje agregacijskog postupka izrađeni su numerički uz uporabu aplikacije za procjenu stanja čiji se kod nalazi u Prilogu 2. disertacije. U svrhu opisa postupka izračuna prikazat će se, u skraćenim koracima, izračun stanja energetskog transformatora za svibanj 2011. godine. Odabrani primjer interesantan je zbog najvećeg broja dostupnih podataka.

Da bi se uspješno pokrenuo postupak izračuna pretpostavlja se da su prikupljeni svi dostupni kvantitativni podaci za osnovne attribute i da su definirane težine za sve (opće i osnovne) attribute. Sukladno kvalitativnim podacima prikazanim u Tablici 7.2. agregacijski postupak kreće od osnovnih atributa prema općim. Složni matematički koraci prilikom izvođenja agregacijskog postupka ovdje su ispušteni, a postupak je detaljno prikazan u [14], [53], [115] prikazuju se samo konačne vrijednosti ocjena općih atributa.

Uzimajući u obzir stupnjeve uvjerenja β_i u ocjene H_n za osnovne attribute e_i i dodijeljene težine ω_i svih atributa, nakon provođenja agregacijskog postupka za opće attribute druge razine imamo slijedeće distribucije:

$$S(\text{Opterećenje}) = \{(\text{izvrstan}, 1)\}$$

$$S(\text{Preostali životni vijek}) = \{(\text{izvrstan}, 1)\}$$

$$S(\text{Brzina starenja}) = \{(\text{izvrstan}, 1)\}$$

$$S(\text{Opći izvedeni atributi}) = \{(\text{izvrstan}, 1)\}$$

$$S(\text{Kapacitet namota}) = \{(\text{izvrstan}, 1)\}$$

$$S(\text{Struja magnetiziranja}) = \{(\text{izvrstan}, 1)\}$$

$S(\text{Djelatni otpor namota}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Kontrola pomaka namota}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Namoti}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Kromatografska analiza}) = \{(\text{nedovoljan}, 0,0295), (\text{vrlo dobar}, 0,2489), (\text{izvrstan}, 0,7216)\}$

$S(\text{Fizikalne veličine}) = (\text{vrlo dobar}, 0,0454), (\text{izvrstan}, 0,08275), (\text{H}, 0,1271)\}$

$S(\text{Električne veličine}) = \{(\text{izvrstan}, 0,7895), (\text{H}, 0,2105)\}$

$S(\text{Tekuće/kruta izolacija}) = \{(\text{nedovoljan}, 0,0084), (\text{vrlo dobar}, 0,0823), (\text{izvrstan}, 0,8306), (\text{H}, 0,0787)\}$

$S(\text{Sušionik zraka kotla}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Nivo ulja kotla}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Popuštanje brtvi}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Kotao}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Mjerenje faktora dielektričnih gubitaka izolacije provodnika}) = \{(\text{dobar}, 0,0563), (\text{vrlo dobar}, 0,2550), (\text{izvrstan}, 0,6886)\}$

$S(\text{Kapacitet izolacije provodnika}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Termovizijsko snimanje provodnika}) = \{(\text{H}, 1)\}$

$S(\text{Indeks promjene kapaciteta primara}) = \{(\text{vrlo dobar}, 0,2951), (\text{izvrstan}, 0,7409)\}$

$S(\text{Indeks promjene kapaciteta sekundara}) = \{(\text{vrlo dobar}, 0,1212), (\text{izvrstan}, 0,8788)\}$

$S(\text{Provodnici}) = \{(\text{dobar}, 0,0035), (\text{vrlo dobar}, 0,1492), (\text{izvrstan}, 0,7920), (\text{H}, 0,0554)\}$

$S(\text{Broj operacija}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Ukupna preključena struja}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Snaga motora reg, sklopke}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Regulacijska sklopka}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Stanje pumpi}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Stanje ventilatora}) = \{(\text{izvrstan}, 1)\}$

$S(\text{Učinkovitost hladnjaka}) = \{(\text{izvrstan}, 0,5355), (\text{H}, 0,4645)\}$

$S(\text{Rashladni sustav}) = \{(\text{izvrstan}, 0,9394), (\text{H}, 0,0606)\}$

Što rezultira slijedećom distribucijom:

$S(ET)_{05/11} = \{(\text{nedovoljan}, 0,0019), (\text{dobar}, 0,0005), (\text{vrlo dobar}, 0,0385), (\text{izvrstan}, 0,9331), (\text{H}, 0,0261)\}$ (7.1)

koja predstavlja ocjenu ukupnog stanja energetskog transformatora za mjesec svibanj 2011. godine.

Iz navedene distribucije vidljivo je da je ukupno stanje energetskog transformatora ocijenjeno ocjenom nedovoljan sa stupnjem uvjerenja u ocjenu od 0,019, ocjenom dobar sa stupnjem uvjerenja u ocjenu od 0,0005, ocjenom vrlo dobar sa stupnjem uvjerenja u ocjenu od 0,0385 i ocjenom izvrstan sa stupnjem uvjerenja u ocjenu od 0,9331. Nesigurnost u ocjenu iznosi 0,0261, a rezultat je nepostojanja i/ili nepoznavanja svih definiranih ulaznih podataka.

Da bi dobili ocjenu lakšu za usporedbu moguće je izračunati ukupnu konačnu procjenu. Za ovu svrhu potrebno je prvo definirati intervale koji predstavljaju pet osnovnih ocjena. Pretpostavimo da su vrijednosti odabrane kako slijedi:

$$u(1) = 0$$

$$u(2) = 0,35$$

$$u(3) = 0,55$$

$$u(4) = 0,85$$

$$u(5) = 1$$

Primjenom izraza od (5.12) do (5.15) na distribuciju danu izrazom (7.1) dobiva se ukupna ocjena stanja promatranog objekta kako slijedi:

$$u((ET)_{05/11})_{min} = 0,9661$$

$$u((ET)_{05/11})_{max} = 0,9921$$

$$u((ET)_{05/11})_{avg} = 0,9791.$$

Također možemo reći da vrijedi:

$$u((ET)_{05/11}) = u((ET)_{05/11})_{avg} \pm \Delta u = 0,9791 \pm 0,013.$$

Koristeći konačnu ocjenu stanja i interval konačne ocjene možemo dobiti jednu numeričku vrijednost i širinu intervala vrijednosti kojom predstavljamo ukupno stanje promatranog objekta. Takvu vrijednost možemo koristiti za usporedbu stanja između različitih promatranih objekata. Također moguće je predstaviti konačnu ocjenu stanja kao funkciju vremena i promatrati promjenu stanja promatranog tijekom perioda eksploatacije kao i poboljšanje ocjene stanja nakon održavanja.

Za sve odabrane vremenske točke proveden je agregacijski postupak, te su rezultati prikazani u Tablici 7.3. iz koje je jasno vidljiv trenutak prikupljanja podataka (vrijeme), stupnjevi uvjerenja u pojedine ocjene (Ocjena 1, Ocjena 2,...), nesigurnost te ukupna procjena stanja (u_{avg} , u_{min} , u_{max}).


Tablica 7.3. Procjene stanja energetskog transformatora u različitim vremenskim točkama

Rb.	Vrijeme	Ocjena 1	Ocjena 2	Ocjena 3	Ocjena 4	Ocjena 5	Nesigurnost	Uavg	Umin	Umax
1.	01.08.05	0,0000	0,0000	0,0331	0,0592	0,3420	0,5656	0,6934	0,4106	0,9762
2.	01.02.06	0,0000	0,0000	0,0304	0,0244	0,4030	0,5422	0,7116	0,4405	0,9827
3.	01.08.06	0,0000	0,0000	0,0586	0,0000	0,3814	0,5600	0,6936	0,4136	0,9736
4.	01.02.07	0,0000	0,0000	0,0665	0,0000	0,3503	0,5832	0,6785	0,3869	0,9701
5.	01.08.07	0,0000	0,0000	0,0486	0,0184	0,7001	0,2329	0,8589	0,7425	0,9754
6.	01.02.08	0,0000	0,0000	0,0059	0,0600	0,3285	0,6056	0,6855	0,3827	0,9884
7.	01.09.08	0,0000	0,0057	0,0643	0,0620	0,2727	0,5954	0,6604	0,3627	0,9581
8.	01.09.09	0,0000	0,0046	0,0000	0,0508	0,4003	0,5443	0,7172	0,4451	0,9894
9.	01.02.10	0,0000	0,0025	0,0045	0,0350	0,7651	0,1930	0,8946	0,7981	0,9911
10.	01.05.10	0,0000	0,0030	0,0000	0,0211	0,7525	0,2234	0,8832	0,7714	0,9949
11.	01.09.10	0,0000	0,0023	0,0006	0,0190	0,7843	0,1938	0,8985	0,8016	0,9954
12.	01.12.10	0,0026	0,0000	0,0027	0,0103	0,7724	0,2119	0,8886	0,7827	0,9946
13.	01.05.11	0,0019	0,0000	0,0005	0,0385	0,9331	0,0261	0,9791	0,9661	0,9922

Iz Tablice 7.3. vidljive su konačne ocjene (distribucije) i ukupna ocjena energetskog transformatora u različitim vremenskim trenucima. Također, jasno je vidljiv utjecaj nepotpunih ulaznih podataka u agregacijski proces kroz povećanu nesigurnost. Zbog povećane nesigurnosti dolazi i do povećane raspršenosti ukupne ocjene u i do povećanog intervala ukupne ocjene Δu .


Slike 7.4. i 7.5 prikazuju odnose između nesigurnosti i parametara ukupne ocjene o trenutku prikupljana podataka.

Tako je na slici 7.4. vidljiv odnos između nesigurnosti, prosječne, minimalne i maksimalne ukupne ocjene. Slika 7.5 prikazuje odnos između nesigurnosti odnosno nepotpunosti ulaznih podataka i prosječne ukupne ocjene. Iz čega je jasno vidljivo da je potpunost ulaznih podatak poželjna. Nesigurnost, za podatke prikupljene do veljače 2010. g. se kreće od vrijednosti 0,54 do 0,6 s izuzetkom kolovoza 2007. g. kada su pored uobičajenih mjerenja provedena i mjerenja električnih veličina (namoti, tekuće/kruta izolacija, provodnici).



Slika 7.4. Odnos nesigurnosti i parametara ukupne ocjene za različite vremenske točke

Najveća nesigurnost prisutna je za mjerenja provedena u veljači 2008. godine kada od modelom predviđenih ulaznih podataka imamo na raspolaganju samo neke od vrijednosti dostupne mjerenjem (kromatografska analiza, vlaga u ulju, termovizijsko snimanje provodnika) i pregledom (kotao, stanje pumpi, stanje ventilatora), a podaci iz sustava za daljinsko prikupljanje podataka nisu dostupni. Od veljače 2010.g. dostupni su podaci iz sustava za udaljeni nadzor što rezultira smanjenjem nesigurnosti, a najmanja zabilježena nesigurnost odnosi se na svibanj 2011. g. kada su bili dostupni gotovo svi podaci predviđeni modelom tj. na raspolaganju su bili ulazni podaci dobiveni mjerenjem, procjenom i sustavom za udaljeni nadzor.



Slika 7.5. Odnos nesigurnosti prosječne ukupne ocjene za različite vremenske točke

Nakon analize dobivenih podataka, na osnovu predloženog modela i postupka ocjene, vidljivo je da treba posvetiti odgovarajuću pažnju ulaznim podacima tj. osigurati što veći broj ulaznih podataka. Dosadašnji postupci u održavanju energetskih transformatora zasnivali su se na redovnom (periodičnoim) li izvanrednom provođenju mjerenja i ispitivanja što rezultira oscilacijama u količini ulaznih podataka. U svrhu usporedbe ocjene, a time i dva ili više stanja promatranog objekta poželjno je uzeti vremenske točke sa što potpunijim podacima. Ukoliko to nije moguće tada je potrebno voditi računa da se uspoređuju stanja sa podjednakim iznosom nesigurnosti.

8. PREDVIĐANJE STANJA SUSTAVA SIVIM MODELOM

Mogućnost predviđanja budućeg stanja promatranog objekta na osnovu podataka o trenutnom i prošlim stanjima interesantno je i aktualno pitanje prilikom održavanja tehničkih sustava. Postoji više različitih postupaka i metoda koje se mogu primijeniti [20], [22], [25], [27], [32], [37], [41], [50], [55], [57], no svaka metoda ima određene prednosti i nedostatke.

Za primjenu u ovom radu odabrana je relativno nova metoda tzv. sivog predviđanja (eng. *grey forecasting*) [33], [50], [78], [85], [93], [94], [107], [108], koja se temelji na teoriji sivih sustava (eng. *grey system theory*). Teorija sivih sustava [30], [26], [33], [37], [39], [78], [102], prvi puta se spominje 1982.g. [29] i od tada ovoj metodi raste popularnost i primjena te se danas uspješno koristi pri rješavanju problema u različitim područjima [23], [24], [38], [39], [52], [54], [55], [58], [75], [85], [93], [94], [102], [103], [111], [117].

Sivim sustavima nazivamo sustave za koje nemamo sve informacije tj. sivi sustav možemo podijeliti na sivi prostor stanja (koji predstavlja nepoznati dio sustava) i bijeli prostor stanja (koji predstavlja poznati dio sustava). Cilj teorije sivih sustava je odrediti nepoznati dio sustava iz poznatog dijela sustava tj. sivi dio sustava iz bijelog dijela sustava. U tu svrhu koristi se odgovarajući matematički aparat.

Dio teorije sivih sustava je i sivo predviđanje. Općenito možemo reći da predviđanjem želimo predvidjeti nepoznate podatke uz pomoć poznatih ili nepoznatih modela. Postoji više stotina različitih metoda namijenjenih predviđanju [33], [35], [41], [50], [64], [93], [106], [111], [120]. Neke od poznatijih su regresijska metoda [77], Delphi metoda, metoda predviđanja na osnovu trenda, metoda modela i dr. Odabrana metoda sivog predviđanja koristi će se za predviđanje $n+1$ elementa niza na osnovu n poznatih elementa.

8.1. Algoritam sivog predviđanja

Za sivo predviđanje [85], [107], [108] odabire se model sivog sustava predstavljen diferencijalnom jednačinom prvog reda s jednom nepoznanicom tj. GM (1,1) (eng. *grey*

model). Sukladno teoriji sivih sustva, GM(1,1) model definiran je diferencijalnom jednačbom prvog reda tj. $\frac{dx^{(1)}}{dt} + ax^{(1)} = b$; gdje su a i b koeficijenti diferencijalne jednačbe, $x^{(0)}$ predstavlja izvorni skup podataka a $x^{(1)}$ predstavlja transformaciju izvornog niza AGO funkcijom (eng. *accumulated generating operation*) tj. operacijom akumuliranog generiranja. AGO funkcija uspješno transformira proizvoljni niz podataka u strogo rastući niz. Takav strogo rastući niz opisuje se funkcijom koju je jednostavnije modelirati, tj. odrediti njezin $n+1$ element, a zatim pomoću postupka inverznog akumuliranog generiranja odrediti slijedeći element originalnog niza. Slijedi prikaz osnovnog algoritma za sivo predviđanje. Pretpostavimo slijedeći niz podataka:

$$x^{(0)} = [x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(k)] \quad (8.1)$$

gdje je k duljina niza a t_1, t_2, \dots, t_k predstavlja vremenske točke prikupljanja podataka.

Ukoliko je riječ o jednolikim vremenskim intervalima tada je daljnji postupak prikazan izrazima od (8.2) do (8.12). Ukoliko je riječ o nejednakim vremenskim intervalima tada je postupak nešto drugačiji. Postoji više modifikacija algoritma sivog predviđanja za nejednolike intervale prikupljanja podataka. Općenito možemo reći da se postupak tada zasniva na prilagodbi ulaznih podataka, a nakon toga slijedi primjena standardnog algoritma sivog predviđanja ili se upotrebljava modificirani algoritam sivog predviđanja kod kojeg je prilagodba provedena prilikom određivanja osnovnih parametara. U ovom radu prikazat će se postupak sivog predviđanja nad podacima s nejednakim intervalom prikupljanja podataka koji će se prvo podvrgnuti postupku prilagodbe, a nakon toga slijedi primjena osnovnog algoritma sivog predviđanja [106]. Postupak prilagodbe ulaznih podataka s nejednakim intervalima prikupljanja prikazan je izrazima od (8.22) do (8.25). Određivanje pogreške predviđanja i određivanje preciznosti modela zajedničko je za predviđanje zasnovano na jednakim i nejednakim intervalima prikupljanja, a opisano je izrazima od (8.13) do (8.21).

Dakle, nakon što je određen niz ulaznih podataka (8.1) odnosno određen je niz prilagođenih ulaznih podataka (za nejednolike intervale prikupljanja) potrebno je pokrenuti postupak akumuliranog generiranja (AGO) nad ulaznim podacima.

$$x^{(1)} = AGO\{x^{(0)}\} = \left[\sum_{k=1}^1 x^{(0)}(k), \sum_{k=1}^2 x^{(0)}(k), \dots, \sum_{k=1}^n x^{(0)}(k) \right] \quad (8.2)$$

Dakle, dobivamo niz akumuliranih vrijednosti:

$$x^{(1)} = [x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(k)] \quad (8.3)$$

Izraz (8.3) zajedno sa slijedećim izrazom:

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b \quad (8.4)$$

čini GM(1,1) model sivog sustava, gdje su a i b takozvani sivi parametri.

Izraz $\frac{dx^{(1)}}{dt}$ možemo prevesti u $\frac{dx^{(1)}}{dt} \rightarrow x^{(1)}(k+1) - x^{(1)}(k)$ gdje vrijedi da je

$$x^{(1)}(k+1) - x^{(1)}(k) = x^{(0)}(k+1) \quad (8.5)$$

Također vrijedi:

$$x^{(1)}(t) \rightarrow 0.5x^{(1)}(k) + 0.5x^{(1)}(k-1) = z^{(1)}(k) \quad k = 2 \dots n \quad (8.6)$$

$$x^{(0)}(k) + az^{(1)}(k) = b \quad (8.7)$$

Rješenje jednadžbe (8.4) dano je sa izrazom:

$$\hat{x}(k+1) = \left(x^{(0)}(1) - \frac{b}{a} \right) e^{-ak} + \frac{b}{a} \quad (8.8)$$

gdje je

$$\begin{aligned} x^{(0)} &= (x^{(0)}(1), x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(k)) \\ x^{(1)} &= (x^{(1)}(1), x^{(1)}(2), x^{(1)}(3), \dots, x^{(1)}(k)) \\ \hat{x}^{(0)}(k+1) &= x^{(1)}(k+1) - \hat{x}^{(1)}(k) \end{aligned} \quad (8.9)$$

što možemo napisati kao

$$\hat{x}^{(1)}(k+1) = (x^{(0)}(1))e^{-ak} + \frac{b}{a}(1 - e^{-ak}) \quad (8.10)$$

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k) \quad (8.11)$$

a konačan izraz za sivo predviđanje tada glasi:

$$\hat{x}^{(0)}(k+1) = (1 - e^{-a})(x^{(0)}(1)) - \frac{b}{a}e^{-ak} \quad (8.12)$$

Da bi se primijenio gornji izraz prvo je potrebno izračunati parametre a i b. To se može napraviti na dva načina tj. metodom najmanjih kvadrata i parametarskom metodom. Metoda najmanjih kvadrata polazi od izraza

$$x^{(0)}(k) + az^{(1)}(k) = b \quad (8.13)$$

i matrične metode $Y = B\hat{a}$ gdje je:

$$Y = \begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ x^{(0)}(4) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} \quad B = \begin{bmatrix} -z^{(1)}(2) & 1 \\ -z^{(1)}(3) & 1 \\ -z^{(1)}(4) & 1 \\ \vdots & \vdots \\ -z^{(1)}(n) & 1 \end{bmatrix} \quad \hat{a} = \begin{bmatrix} a \\ b \end{bmatrix} \quad (8.14)$$

tada vrijedi da je

$$\hat{a} = (B^T B)^{(-1)} B^T Y \quad (8.15)$$

što rezultira traženim izrazima a i b.

Parametarska metoda zasniva se na izračunu parametara C, D, E, F gdje vrijedi:

$$C = \sum_{k=2}^n z^{(1)}(k), D = \sum_{k=2}^n x^{(0)}(k), E = \sum_{k=2}^n z^{(0)}(k)x^{(0)}(k), F = \sum_{k=2}^n z^{(1)}(k)^2 \quad (8.16)$$

tada se vrijednosti a i b računaju prema izrazima

$$a = \frac{CD - (n-1)E}{(n-1)F - C^2}, b = \frac{DF - CE}{(n-1)F - C^2} \quad (8.17)$$

nakon što su određeni parametri a i b može se prema izrazu (8.12) odrediti vrijednosti koje daje algoritam sivog predviđanja. Točnost predviđanja [119], [110] određuje se standardnim statističkim postupcima tj. testom dobrote:

$$C = S_2 / S_1 \quad (8.18)$$

gdje su :

$$S_1^2 = \frac{1}{k} \sum_{i=1}^k (x^{(0)}(i) - \bar{x})^2 \quad (8.19)$$

$$S_2^2 = \frac{1}{k} \sum_{i=1}^k (\zeta^{(0)}(i) - \bar{\zeta})^2 \quad (8.20)$$

gdje je $\zeta^{(0)}(i) = x^{(0)}(i) - \hat{x}^{(0)}(i)$, a S_1^2 i S_2^2 predstavljaju kvadrat standardne devijacije za podatke i pogrešku. Test dobrote definiran izrazom (8.18) je omjer standardnih devijacija, a izraz:

$$P = p\left\{(\zeta^{(0)}(i) - \bar{\zeta}) < 0.6745 S_1\right\} \quad (8.21)$$

predstavlja vjerojatnost da je razlika između greške $\zeta^{(0)}(i)$ i prosječne greške $\bar{\zeta}$ manja od vrijednosti koju daje standardna devijacija S_1 pomnožena s 0.6745.

Tablica 8.1 predstavlja ocjenu preciznosti za predviđanje na osnovu vrijednosti P i C .

Tablica 8.1. Određivanje preciznosti predviđanja

Ocjena preciznosti	P	C
Vrlo dobra (Razina 1)	>0.95	<0.35
Dobra (Razina 2)	>0.80	<0.50
Dovoljna (Razina 3)	>0.70	<0.65
Nedovoljna (Razina 4)	<0.70	>0.65

Gornji postupak u potpunosti zadovoljava algoritam sivog predviđanja nad podacima s jednakim intervalom prikupljanja. U praksi je ponekad teško doći do podataka prikupljenih u jednakim intervalima tj. intervali prikupljanja podataka u najvećem broju slučajeva nisu jednaki. Ukoliko je potrebno izvršiti algoritam sivog predviđanja nad podacima s nejednakim intervalom prikupljanja potrebno je prilagoditi ulazne podatke tako da se svedu na jednake vremenske intervale. Takav postupak prilagodbe naziva se vremensko ujednačavanje, a provodi se kako slijedi.

Neka je prosječni vremenski interval definiran sa:

$$\Delta t = \frac{t_n - t_1}{n - 1} \quad (8.22)$$

gdje je Δt prosječni vremenski interval, t_1 vrijeme prikupljanja prvog podatka, t_n vrijeme prikupljanja n -tog podatka, a n odgovara broj prikupljenih podataka.

Koeficijent vremenskog pomaka računa se prema:

$$\theta(t_i) = \frac{t_i - (i - 1)\Delta t_0}{\Delta t_0} \quad (i = 1, 2, 3, \dots, n) \quad (8.23)$$

a razlika za svaki element niza dana je sa:

$$\Delta X_0^{(0)}(t_i) = \theta(t_i) [X_0^{(0)}(t_i) - X_0^{(0)}(t_{i-1})] \quad (i = 1, 2, 3, \dots, n) \quad (8.24)$$

Konačno na osnovu izraza od (8.22) do (8.24) možemo definirati novi niz ulaznih podataka s jednakim vremenskim intervalom čije vrijednosti se računaju prema:

$$X^{(0)}(t_i) = X_0^{(0)}(t_i) - \Delta X_0^{(0)}(t_i) \quad (i = 1, 2, 3, \dots, n) \quad (8.25)$$

Na ovako pripremljenim i prilagođenim podacima može se započeti sa standardnim algoritmom sivog predviđanja koji je opisan izrazima od (8.1) do (8.12) gdje je niz definiran izrazom (8.1) zamijenjen nizom definiranim s (8.25).

8.2. Predviđanje rezultata komatografske analize otopljenih plinova u ulju energetskog transformatora

U ovom poglavlju prikazat će mogućnost primjene algoritam sivog predviđanja nad podacima proizašlim iz redovitih mjerenja i sustava za udaljeni nadzor i prikupljanje podataka. Skup podataka na kojem bi bilo interesantno ispitati mogućnosti algoritma za predviđanje je skup podataka tj. osnovnih atributa vezan uz kromatografsku analizu plinova otopljenih u ulju energetskog transformatora [35], [38], [97]. Problem plinova otopljenih u ulju kao i postupci preventivnog održavanja i analize potencijalnih neželjenih stanja na osnovu udjela otopljenih plinova prikazani su u [4], [31], [94], [111].

Tablica 8.2. Izvorni podaci za osnovne attribute koromatografske analize

				KROMATOGRAFSKA ANALIZA (0,35)						
				Vodik	Metan	Acitilen	Etilen	Etan	Ugljični monoksid	Ugljični dioksid
				0,350 23	0,050 24	0,400 25	0,050 26	0,050 27	0,050 28	0,050 29
	Rb	Vrije- me	Δt	$\mu\text{l/l}$ (ppm)	$\mu\text{l/l}$ (ppm)	$\mu\text{l/l}$ (ppm)	$\mu\text{l/l}$ (ppm)	$\mu\text{l/l}$ (ppm)	$\mu\text{l/l}$ (ppm)	$\mu\text{l/l}$ (ppm)
KVANTITATIVNI PODACI	1	08/05	0	78	5	<0,1	<0,1	0,4	342	469
	1	0206	6	76	6	<0,1	<0,1	<0,1	356	445
	2	08/06	12	83	9	0	0,4	4	432	686
	3	02/07	18	86	9	0	0	0,9	454	678
	5	08/07	24	71	9	0	0	1	477	928
	6	02/08	30	65	10	0	0	1,7	468	722
	7	09/08	37	60	13	0	0	5	537	1053
	8	09/09	49	52	14	0	0	3	614	1247
	10	02/10	54	38	14	1	1	3	568	1340
	9	05/10	57	35	16	1	2	3	584	1620
	11	09/10	61	29	15	1	2	4	639	2004
	12	12/10	64	30	19	2	1	7	650	1950
	13	05/11	70	39	20	2	2	11	720	2552
KVALITATIVNI PODACI	1	08/05	0	3,5	5	5	5	5	3	5
	1	0206	6	3,5	5	5	5	5	3	5
	2	08/06	12	3	5	5	5	5	3	5
	3	02/07	18	3	5	5	5	5	3	5
	5	08/07	24	3,5	5	5	5	5	3	5
	6	02/08	30	4	5	5	5	5	2	5
	7	09/08	37	4	4,5	5	5	5	2	5
	8	09/09	49	4	4,5	5	5	5	2	5
	10	02/10	54	4,5	4,5	5	5	5	2	5

	9	05/10	57	4,5	4,5	5	5	5	2	4
	11	09/10	61	5	4,5	5	5	5	2	4
	12	12/10	64	5	4	5	5	5	1	4
	13	05/11	70	4,5	4	5	5	4,5	1	4

PRAVILA PRETVARANJA	5		<37,5	<15	<32,5	<22,5	<10	<162,5	<1430
	4		<75	<30	<65	<45	<20	<325	<2865
	3		<112,5	<45	<97,5	<67,5	<30	<487,5	<4300
	2		<150	<60	<130	>90	<40	<650	<5730
	1		>150	>60	>130	>90	>40	>650	>5730

Podaci prikupljeni kromatografskom analizom raspoloživi su za svih trinaest vremenskih točaka te zbog toga pogodni su za primjenu algoritma sivog predviđanja [93]. Tablica 8.2 prikazuje izvorne podatke prikupljene kromatografskom analizom kroz period od kolovoza 2005. godine pa do svibnja 2011. godine. Podaci proizlaze iz redovitih mjerenja (08/2005 – 09/2019) i ugrađenog sustava za udaljeni nadzor i prikupljanje podataka (02/2010 – 05/2011).

Kako su podaci prikupljeni u nepravilnim vremenskim intervalima [26], prije primjene algoritma sivog predviđanja, potrebno ih prilagoditi. Prilagodba podataka vrši se sukladno izrazima od (8.23) do (8.25), a prilagođeni podaci nalaze se prikazani u Tablici 8.3. Podaci iz Tablice 8.3 sada predstavljaju ulaz u algoritam sivog predviđanja opisan izrazima od (8.1.) do (8.12.). Analiza greške i preciznosti predviđanja računa se prema izrazima od (8.18.) do (8.21.).

Tablica 8.3. Prilagođeni podaci za osnovne atribute koromatografske analize

n	Vremenski korak	Δt	Vodik	Metan	Acitilen	Etilen	Etan	Ugljični monoksid	Ugljični dioksid
1	0,00	5,83	78,00	5,00	0,10	0,10	0,40	342,00	469,00
2	5,83	5,83	76,06	5,97	0,10	0,10	0,11	355,60	445,69
3	11,67	5,83	82,60	8,83	0,01	0,38	3,78	427,66	672,23
4	17,50	5,83	85,74	9,00	0,00	0,03	1,17	452,11	678,69
5	23,33	5,83	72,71	9,00	0,00	0,00	0,99	474,37	899,43
6	29,17	5,83	65,86	9,86	0,00	0,00	1,60	469,29	751,43
7	35,00	5,83	61,71	11,97	0,00	0,00	3,87	513,34	939,51
8	40,83	5,83	63,20	12,60	0,00	0,00	5,80	506,20	975,40
9	46,67	5,83	55,60	14,00	0,26	0,26	3,00	625,83	1223,09
10	52,50	5,83	37,31	14,46	1,00	1,23	3,00	571,66	1404,00
11	58,33	5,83	31,74	15,46	1,00	2,00	3,54	613,86	1828,46
12	64,17	5,83	30,03	19,11	2,03	0,97	7,09	650,31	1948,46
13	70,00	5,83	39,00	20,00	2,00	2,00	11,00	720,00	2552,00

Predviđanje se može vršiti na više načina, a odabrani način (odabrana duljina niza izvornih podataka) ovisit će o tehničkom procesu i prirodi podatka koji se predviđa.

Predložena metoda sivog predviđanja pokazala se uspješnom za predviđanje vrijednosti na osnovu malog broja ulaznih podataka. Radi ilustracije metode prikazat ćemo različite mogućnosti predviđanja za različite elemente iz tablice 8.3. Za sva predviđanja dat će se izračun pogreške i ocjena preciznosti. Tablica 8.4. i 8.5. prikazuju predviđanje razine vodika i metana otopljenog u transformatorskom ulju na osnovu postojećih dvanaest vrijednosti i vrši se usporedba predviđene i stvarne trinaeste vrijednosti. Prikazana je pogreška predviđanja za pojedine korake i ukupna prosječna pogreška predviđanja.

Tablica 8.4. Predviđanje razine vodika na osnovu postojećih podataka

Izvorni podaci													
Item	1	2	3	4	5	6	7	8	9	10	11	12	
X(0)	78,00	76,06	82,60	85,74	72,71	65,86	61,71	63,2	55,60	37,31	31,74	30,03	
Rezultati sivog predviđanja													
k	Izvorni podatak					Predviđeni podataka				greška(%)			
1	78,00					78,00				0,00			
2	76,06					89,64				-17,86			
3	82,60					82,25				0,42			
4	85,74					75,47				11,98			
5	72,71					69,25				4,77			
6	65,86					63,54				3,52			
7	61,71					58,30				5,53			
8	63,20					53,49				15,36			
9	55,60					49,08				11,72			
10	37,31					45,04				-20,70			
11	31,74					41,32				-30,19			
12	30,03					37,92				-26,27			
13	39,00					34,79				10,79			
Prosječna greška											12,24		

Tablice 8.6. i 8.7. prikazuju takozvanu kotrljajuću metodu predviđanja primijenjenu nad podacima za udio vodika i metana.

Tablica 8.5. Predviđanje razine metana na osnovu postojećih podataka

Izvorni podaci												
Item	1	2	3	4	5	6	7	8	9	10	11	12
X(0)	5,00	5,97	8,83	9,00	9,00	9,86	11,97	12,60	14,00	14,46	15,46	19,11
Rezultati sivog predviđanja												
k	Izvorni podatak					Predviđeni podataka				greška(%)		
1	5,00					5,00				0,00		
2	5,97					7,06				-18,16		
3	8,83					7,75				12,16		
4	9,00					8,52				5,29		
5	9,00					9,37				-4,10		
6	9,86					10,30				-4,47		
7	11,97					11,32				5,45		
8	12,60					12,44				1,26		
9	14,00					13,67				2,33		
10	14,46					15,03				-3,96		

11	15,46	16,52	-6,88
12	19,11	18,16	4,98
13	20,00	19,96	0,21
Prosječna greška			5,00

Također, u tablicama je vidljiva pogreška pojedinih koraka predviđanja i ukupna prosječna pogreška.

Kotrljajuća metoda (eng. *rolling method*) zapravo je primjena standardne metode sivog predviđanja na nizu od n elemenata, na način da se odredi korak kotrljanja tj. duljina niza na osnovu kojeg će se vršiti predviđanje. Korak kotrljanja $k < n$, a primjenjuje se na k elemenata niza tako da se u prvom koraku metode kreće od prvog ($n=1$) elementa niza i predviđa se $k+1$ element.

Tablica 8.6. Predviđanje razine vodika kotrljajućom metodom

Izvorni podaci												
Item	1	2	3	4	5	6	7	8	9	10	11	12
X(0)	78,00	76,06	82,60	85,74	72,71	65,86	61,71	63,2	55,60	37,31	31,74	30,03
Rezultati sivog predviđanja												
k	Izvorni podatak					Predviđeni podaci				greška(%)		
1	78,00					78,00				0,00		
2	76,06					76,69				-0,83		
3	82,60					81,35				1,52		
4	85,74					86,29				-0,64		
5	72,71					91,54				-25,89		
Prosječna greška (%)										5,78		
2	76,06					76,06				0,00		
3	82,60					85,16				-3,10		
4	85,74					80,24				6,42		
5	72,71					75,61				-3,98		
6	65,86					71,24				-8,14		
Prosječna greška (%)										4,33		
3	82,60					82,60				0,00		
4	85,74					84,92				0,96		
5	72,71					74,22				-2,07		
6	65,86					64,87				1,49		
7	61,71					56,70				8,12		
Prosječna greška (%)										2,53		
4	85,74					85,74				0,00		
5	72,71					72,33				0,53		
6	65,86					66,57				-1,09		
7	61,71					61,28				0,71		
8	63,20					56,40				10,75		
Prosječna greška (%)										2,62		
5	72,71					72,71				0,00		
6	65,86					64,94				1,39		
7	61,71					63,58				-3,02		
8	63,20					62,24				1,51		
9	55,60					60,94				-9,60		
Prosječna greška (%)										3,10		
6	65,86					65,86				0,00		
7	61,71					63,17				-2,35		
8	63,20					60,11				4,88		

9	55,60	57,21	-2,89
10	37,31	54,44	45,90
Prosječna greška (%)			11,21
7	61,71	61,71	0,00
8	63,20	64,73	-2,41
9	55,60	50,95	8,36
10	37,31	40,11	-7,50
11	31,74	31,58	0,52
Prosječna greška (%)			3,76
8	63,20	63,20	0,00
9	55,60	54,12	2,66
10	37,31	40,09	-7,43
11	31,74	29,69	6,46
12	30,03	21,99	30,08
Prosječna greška (%)			9,33
9	55,60	55,60	0,00
10	37,31	36,76	1,48
11	31,74	32,86	-3,51
12	30,03	29,36	2,21
13	30,00	26,24	12,50
Prosječna greška (%)			3,94
10	37,31	37,31	0,00
11	31,74	29,79	6,14
12	30,03	33,38	-11,17
13	39,00	37,41	4,07
Prosječna greška (%)		41,93	5,35
Ukupna prosječna greška (%)			5,2

U drugom koraku metode kreće se od drugog elementa niza uz isti korak kotrljanja k i predviđa se $k+2$ element niza, itd.. Općenito možemo reći da kotrljajuća metoda ima definiran korak kotrljanja $k < n$, a sastoji se od i iteracija gdje se u svakoj i -toj iteraciji kreće od i -tog elementa niza, uzima k elemenata niza kao ulaz u postupak predviđanja, predviđa se $k + i$ element niza, za svaki $i=1, \dots, n+1-k$.

Tablica 8.7. Predviđanje razine metana kotrljajućom metodom

Izvorni podaci												
Item	1	2	3	4	5	6	7	8	9	10	11	12
X(0)	5	5,97	8,83	9,00	9,00	9,86	11,97	12,60	14,00	14,46	15,46	19,11
Rezultati sivog predviđanja												
k	Izvorni podatak					Predviđeni podaci					greška(%)	
1	5,00					5,00					0,00	
2	5,97					6,54					-9,59	
3	8,83					7,83					11,25	
4	9,00					9,38					-4,23	
5	9,00					11,23					-24,78	
Prosječna greška (%)											9,97	
2	5,97					5,97					0,00	
3	8,83					8,86					-0,33	
4	9,00					8,94					0,64	
5	9,00					9,03					-0,32	
6	9,86					9,12					7,52	
Prosječna greška (%)											1,76	

3	8,83	8,83	0,00
4	9,00	8,85	1,64
5	9,00	9,28	-3,08
6	9,86	9,72	1,37
7	11,97	10,19	14,89
Prosječna greška (%)			4,20
4	9,00	9,00	0,00
5	9,00	8,78	2,42
6	9,86	10,18	-3,24
7	11,97	11,79	1,50
8	12,60	13,66	-8,42
Prosječna greška (%)			3,12
5	9,00	9,00	0,00
6	9,86	10,15	-3,00
7	11,97	11,41	4,67
8	12,60	12,83	-1,79
9	14,00	14,42	-2,96
Prosječna greška (%)			2,49
6	9,86	9,86	0,00
7	11,97	11,84	1,09
8	12,60	12,82	-1,76
9	14,00	13,88	0,82
10	14,46	15,04	-4,00
Prosječna greška (%)			1,54
7	11,97	11,97	0,00
8	12,60	12,77	-1,38
9	14,00	13,66	2,43
10	14,46	14,61	-1,04
11	15,46	15,62	0,54
Prosječna greška (%)			1,08
8	12,60	12,60	0,00
9	14,00	13,91	0,66
10	14,46	14,62	-1,14
11	15,46	15,37	0,54
12	19,11	16,16	15,42
Prosječna greška (%)			3,55
9	14,00	14,00	0,00
10	14,46	13,98	3,27
11	15,46	16,18	-4,70
12	19,11	18,73	2,00
13	20,00	21,67	-8,36
Prosječna greška (%)			3,67
10	14,46	14,46	0,00
11	15,46	16,01	-3,57
12	19,11	18,08	5,40
13	20,00	20,42	-2,09
Prosječna greška (%)		23,06	2,76
Ukupna prosječna greška (%)			3,41

Kao što je prikazano, predviđanje je moguće obavljati nad različitim podskupovima osnovnog niza ulaznih podataka. Na osnovu raspoloživih podataka i potrebe da se od postojećeg niza podataka što pouzdanije odredi vrijednost sljedećeg podatka u nizu, primijenit će se sljedeći postupak. Uzet će se posljednjih pet vrijednosti za svaki

osnovni atribut. Napravit će se predviđanje na osnovu prve četiri vrijednosti, a zatim će se odrediti greška i preciznost modela pri usporedbi s poznatom petom vrijednošću. Tablice od 8.8. do 8.14. prikazuju predviđenu vrijednost, grešku i ocjenu preciznosti za sve osnovne attribute kromatografske analize tj. za udio otopljenog vodika, metana, acetilena, etilena, etana, ugljičnog monoksida i ugljičnog dioksida.

Tablica 8.8. Predviđanje razine vodika, greška predviđanja, preciznost modela

Izvorni podaci				
Uzorak	1	2	3	4
X(0)	55,60	37,31	31,74	30,03
Rezultati sivog predviđanja				
n	Izvorni podatak	Predviđanja	Greška predviđanja(%)	
1	55,60	55,60	0,00	
2	37,31	36,76	1,48	
3	31,74	32,86	-3,51	
4	30,03	29,36	2,21	
5	39	26,24	32,72	
Prosječna greška			7,98	
	P	C	Preciznost predviđanja	
	0,8	0,57	Razina 2	

Tablica 8.9. Predviđanje razine metana, greška predviđanja, preciznost modela

Izvorni podaci				
Uzorak	1	2	3	4
X(0)	14,00	14,46	15,46	19,11
Rezultati sivog predviđanja				
n	Izvorni podatak	Predviđanje	Greška predviđanja (%)	
1	14,00	14,00	0,00	
2	14,46	13,98	3,28	
3	15,46	16,18	-4,71	
4	19,11	18,73	2,00	
5	20,00	21,68	8,40	
Prosječna greška			3,68	
	P	C	Preciznost predviđanja	
	1,0	0,33	Razina 1	

Tablica 8.10. Predviđanje razine acetilena, greška predviđanja, preciznost modela

Izvorni podaci				
Uzorak	1	2	3	4
X(0)	0,25	1,00	1,00	2,03
Rezultat sivog predviđanja				
n	Izvorni podatak	Predviđanje	Greška predviđanja(%)	
1	0,25	0,25	0,00	
2	1,00	0,78	22,17	

3	1,00	1,20	-19,74
4	2,03	1,84	9,16
5	2,00	2,83	-41,71
Prosječna greška			11,55
	P	C	Preciznost predviđanja
	0,8	0,53	Razina 2

Tablica 8.11. Predviđanje razine etilena, greška predviđanja, preciznost modela

Izvorni podaci				
Uzorak	1	2	3	4
X(0)	0,25	1,23	2,00	0,97
Rezultati sivog predviđanja				
n	Izvorni podatak	Predviđanje	Greška predviđanja(%)	
1	0,25	0,25	0,00	
2	1,23	1,51	-22,65	
3	2,00	1,40	30,12	
4	0,97	1,30	-33,55	
5	2,00	1,20	39,84	
Prosječna greška			25,23	
	P	C	Preciznost predviđanja	
	0,6	0,65	Razina 3	

Tablica 8.12. Predviđanje razine etana, greška predviđanja, preciznost modela

Izvorni podaci				
Uzorak	1	2	3	4
X(0)	3,00	3,00	3,54	7,09
Rezultat sivog predviđanja				
n	Izvorni podatak	Predviđanje	Greška predviđanja(%)	
1	3,00	3,00	0,00	
2	3,00	2,39	20,37	
3	3,54	3,92	-10,63	
4	7,09	6,42	9,37	
5	11,00	10,53	4,29	
Prosječna greška			8,93	
	P	C	Preciznost predviđanja	
	1,0	0,13	Razina 1	

Tablica 8.13. Predviđanje razine ugljičnog monoksida, greška predviđanja, preciznost modela

Izvorni podaci				
Uzorak	1	2	3	4
X(0)	625,83	571,66	613,86	650,31
Rezultati sivog predviđanja				
n	Izvorni podatak	Predviđanje	Greška predviđanja(%)	
1	625,83	625,83	0,00	

2	571,66	572,92	-0,22
3	613,86	610,88	0,49
4	650,31	651,35	-0,16
5	720,00	694,50	3,54
Prosječna greška			0,88
	P	C	Preciznost predviđanja
	1,0	0,24	Razina 1

Tablica 8.14. Predviđanje razine ugljičnog dioksida, greška predviđanja, preciznost modela

Izvorni podaci				
Uzorak	1	2	3	4
X(0)	1223,09	1404,00	1828,46	1948,46
Rezultati sivog predviđanja				
n	Izvorni podatak	Predviđanje	Greška predviđanja(%)	
1	1223,09	1223,09	0,00	
2	1404,00	1468,21	-4,57	
3	1828,46	1710,58	6,45	
4	1948,46	1992,98	-2,28	
5	2552,00	2321,99	9,01	
Prosječna greška			4,46	
	P	C	Preciznost predviđanja	
	1,0	0,21	Razina 1	

Iz prikazanih tablica vidimo iznos greške predviđanja i ocjenu preciznosti. Može se reći da predloženi algoritam sivog predviđanja zadovoljavajuće predviđa $n + 1$ vrijednost na osnovu n postojećih vrijednosti niza. Tablice od 8.15. do 8.21. prikazuju predviđanje na osnovu svih pet odabranih vrijednosti i daju nam predviđanje za sljedeću vremensku točku pomaknutu od posljednje za Δt vrijeme (u primjeru Δt iznosi 5,8 mjeseci). U tablicama je prikazana pogreška po koracima i prosječna pogreška temeljna na poznatim podacima. Podaci za $n+1$ vremenski trenutak još nisu poznati.

Tablica 8.15. Predviđanje razine vodika, greška predviđanja bez kontrolne vrijednosti

Izvorni podaci					
Uzorak	1	2	3	4	5
X(0)	55,60	37,31	31,74	30,03	30,00
Rezultati predviđanja					
n	Izvorni podatak	Predviđanje		Greška predviđanja(%)	
1	55,60	55,60		0,00	
2	37,31	33,97		8,95	
3	31,74	34,33		-8,17	
4	30,03	34,70		-15,55	
5	39,00	35,07		10,08	
6		35,44			
Prosječna greška				8,55	

Tablica 8.16. Predviđanje razine metana, greška predviđanja bez kontrolne vrijednosti

Izvorni podaci					
Uzorak	1	2	3	4	5
X(0)	14,00	14,46	15,46	19,11	20,00

Rezultati sivog predviđanja			
n	Izvorni podatak	Predviđanje	Greška predviđanja(%)
1	14,00	14,00	0,00
2	14,46	14,34	0,82
3	15,46	16,12	-4,28
4	19,11	18,12	5,21
5	20,00	20,37	-1,83
6		22,89	
Prosječna greška			2,43

Tablica 8.17. Predviđanje razine acetilena, greška predviđanja bez kontrolne vrijednosti

Izvorni podaci					
Uzorak	1	2	3	4	5
X(0)	0,10	1,00	1,00	2,03	2,00

Rezultati sivog predviđanja			
n	Izvorni podatak	Predviđanje	Greška predviđanja(%)
1	0,10	0,10	0,00
2	1,00	0,97	2,54
3	1,00	1,26	-26,45
4	2,03	1,64	19,10
5	2,00	2,13	-6,44
6		2,76	
Prosječna greška			10,91

Tablica 8.18. Predviđanje razine etilena, greška predviđanja bez kontrolne vrijednosti

Izvorni podaci					
Uzorak	1	2	3	4	5
X(0)	0,10	1,23	2,00	0,97	2,00

Rezultati sivog predviđanja			
n	Izvorni podatak	Predviđanje	Greška predviđanja(%)
1	0,10	0,10	0,00
2	1,23	1,35	-10,33
3	2,00	1,48	26,19
4	0,97	1,61	-65,66
5	2,00	1,75	12,36
6		1,91	
Prosječna greška			22,91

Tablica 8.19. Predviđanje razine etan, greška predviđanja bez kontrolne vrijednosti

Izvorni podaci					
Uzorak	1	2	3	4	5
X(0)	3,00	3,00	3,54	7,08	11,00
Rezultat sivog predviđanja					
n	Izvorni podatak	Predviđanje		Greška predviđanja(%)	
1	3,00	3,00		0,00	
2	3,00	2,47		17,79	
3	3,54	3,97		-12,26	
4	7,08	6,40		9,56	
5	11,00	10,32		6,20	
6		16,63			
Prosječna greška				9,16	

Tablica 8.20. Predviđanje razine ugljičnog monoksida, greška predviđanja bez kontrolne vrijednosti

Izvorni podaci					
Uzorak	1	2	3	4	5
X(0)	625,83	571,66	613,86	650,31	720,00
Rezultati sivog predviđanja					
n	Izvorni podaci	Predviđanje		Greška predviđanja(%)	
1	625,83	625,83		0,00	
2	571,66	567,78		0,68	
3	613,86	612,57		0,21	
4	650,31	660,89		-1,63	
5	720,00	713,03		0,97	
6		769,27			
Prosječna greška				0,70	

Tablica 8.21. Predviđanje razine ugljičnog dioksida, greška predviđanja bez kontrolne vrijednosti

Izvorni podaci					
Uzorak	1	2	3	4	5
X(0)	1223,09	1404,00	1828,46	1948,46	2552,00
Rezultati sivog predviđanja					
n	Izvorni podatak	Predviđanje		Greška predviđanja(%)	
1	1223,09	1223,09		0,00	
2	1404,00	1422,99		-1,35	
3	1828,46	1715,24		6,19	
4	1948,46	2067,51		-6,11	
5	2552,00	2492,12		2,35	
6		3003,94			
Prosječna greška				3,20	

Na osnovu predviđenih vrijednosti osnovnih atributa može se izvršiti pretvorba iz kvantitativnih u kvalitativne ocjene sukladno pravilima pretvaranja danim u Tablici 7.3. i Tablici 8.2. Nakon određivanja kvalitativnih ocjena osnovnih atributa može se pokrenuti agregacijski postupak i odrediti, sada predviđena, ocjena kromatografske analize za $n+1$ vremenski trenutak. Kvantitativni i kvalitativni podaci za predviđene vrijednosti prikazane su u Tablici 8.22. Predviđena ocjena kromatografske analize za $n+1$ vremenski trenutak (listopad 2011. g.) prikazana je u tablici 8.23. Uz pretpostavku postojanja podataka za ostale osnovne atribute može se izvršiti predviđanje vrijednosti osnovnih atributa za $n+1$ trenutak, a koristeći ovdje prikazani postupak u konačnici bi se mogla prikazati ukupna predviđena ocjena energetskog transformatora za $n+1$ vremenski trenutak.

Tablica 8.22. Predviđanje razine ugljičnog dioksida, greška predviđanja bez kontrolne vrijednosti

n	Vremenski korak	Δt	Vodik	Metan	Acitilen	Etilen	Etan	Ugljični monoksid	Ugljični dioksid
1	0,00	5,83	78,00	5,00	0,10	0,10	0,40	342,00	469,00
2	5,83	5,83	76,06	5,97	0,10	0,10	0,11	355,60	445,69
3	11,67	5,83	82,60	8,83	0,01	0,38	3,78	427,66	672,23
4	17,50	5,83	85,74	9,00	0,00	0,03	1,17	452,11	678,69
5	23,33	5,83	72,71	9,00	0,00	0,00	0,99	474,37	899,43
6	29,17	5,83	65,86	9,86	0,00	0,00	1,60	469,29	751,43
7	35,00	5,83	61,71	11,97	0,00	0,00	3,87	513,34	939,51
8	40,83	5,83	63,20	12,60	0,00	0,00	5,80	506,20	975,40
9	46,67	5,83	55,60	14,00	0,26	0,26	3,00	625,83	1223,09
10	52,50	5,83	37,31	14,46	1,00	1,23	3,00	571,66	1404,00
11	58,33	5,83	31,74	15,46	1,00	2,00	3,54	613,86	1828,46
12	64,17	5,83	30,03	19,11	2,03	0,97	7,09	650,31	1948,46
13	70,00	5,83	39,00	20,00	2,00	2,00	11,00	720,00	2552,00
14	75,83	5,83	35,44	22,89	2,76	1,91	16,63	769,27	3003,94
14	Ocjene:		4,5	4	5	5	4	1	3

Tablica 8.23. Procjene stanja energetskog transformatora u različitim vremenskim točkama

Rb.	Vrijeme	Ocjena 1	Ocjena 2	Ocjena 3	Ocjena 4	Ocjena 5	Nesigurnost	Uavg	Umin	Umax
14.	10/2011	0,0303	0,0000	0,0303	0,2338	0,7057	0,00	0,921	0,921	0,921

Za konkretni primjer energetskog transformatora, na osnovu podataka dobivenih iz tvrtke HEP d.d. nije proveden agregacijski postupak nad skupom podataka koji predstavlja predviđeno stanje u $n+1$ vremenskom trenutku zbog nepostojanja

odgovarajućeg vremenskog slijeda podataka. Stoga je metoda prikazana nad podacima za koje postoji dovoljan broj podatka prikupljenih u zadovoljavajućem vremenskom slijedu tj. na podacima provedene kromatografske analize. Na osnovu odabranog skupa podataka prikazana je primjena algoritma sivog predviđanja, analiza pogreške i preciznost modela, te se može reći da se predloženi algoritam sivog predviđanja može zadovoljavajuće upotrijebiti za predviđanja prilikom održavanja tehničkih sustava, naravno uz uvjet da postoji dovoljan broj relevantnih podataka u odgovarajućem vremenskom slijedu. Za provođenje algoritma sivog predviđanja minimalni potreban slijed podatka je niz od tri vrijednosti koje predstavljaju pojedini osnovni atribut.

9. RASPRAVA

Održavanje tehničkih sustava modelom procjene stanja zahtijeva donošenje odluka o održavanju na osnovu višestrukih atributa, primjenom analize zasnovane na višestrukim atributima prikazane u primjerima u poglavlju sedam. Promatrani osnovni ili opći atributi, odnosno njihove ocjene mogu posjedovati određenu količinu nesigurnosti tj. nepotpunosti poznavanja informacije što nepovoljno utječe na sam postupak procjene. Pojava nesigurnosti ovisi o količini informacija tj. o raspoloživim podacima, procjeniteljevom poznavanju opreme i uređaja ugrađenih u promatrani objekt i o mogućnosti potpune procjene pojedinih atributa.

9.1. Dekompozicijski model energetskeg transformatora

U prikazanim primjerima vidljivo je da je neke attribute moguće potpuno procijeniti odgovarajućom ocjenom, ali da uvijek postoji određeni dio informacija gdje se pojava nesigurnosti ne može izbjeći, a ponekad nesigurnost može biti i značajno izražena. Analiza podataka prikupljenih tehničkom dijagnostikom sustava, pridruživanje odgovarajućih ocjena i donošenje odluka mora se provesti na objektivan, pouzdan, ponovljiv i transparentan način. Postavljeni uvjeti mogu se ispuniti korištenjem poboljšanog algoritma evidencijskog zaključivanja kao alata za donošenje odluka u okruženju s višestrukim atributima [42], [49], [53], [59], [68], [104], [105]. Poboljšani algoritam evidencijskog zaključivanja ispunjava sva četiri aksioma sinteze [115], [116], i omogućava atributima sudjelovanje u procjeni na osnovi njihovi individualnih težina. Na prikazanom primjeru jasno je predstavljen različit utjecaj atributa na osnovu razlike u njihovim težinama tj. različitih individualnih težinskih koeficijenata. Odabir težinskih koeficijenata najčešće je rezultat procjeniteljevog poznavanja tehničkog sustava i proizvodnog procesa.

9.1. Procjena stanja

Poboljšani algoritam evidencijskog zaključivanja je robustan (otporan) na nepotpune informacije o osnovnim ili općim atributima, što je bitno svojstvo koje omogućava uvid

u utjecaj nepotpunog poznavanja informacije vezane uz osnovni atribut te na ukupnu nesigurnost u procjeni cjelokupnog tehničkog sustava. Podrazumijeva se da nesigurnost konačne ocjene mora biti u razumnim granicama da bi ukupna procjena sustava imala smisla. Također, moguće je prikazati rezultat procjene stanja kao jednu numeričku vrijednost s intervalom od minimalne do maksimalne vrijednosti umjesto procjene koja je raspodijeljena između nekoliko unaprijed definiranih ocjena. Takva numerička vrijednost omogućava jednostavan uvid u stanje sustava i usporedbu stanja promatranog sustava s drugim sličnim sustavima ili sa stanjem istog tehničkog sustava u drugom vremenskom trenutku. Poseban naglasak dan je na pravilnu interpretaciju fizikalnih veličina dobivenih mjerenjima na parametrima sustava. Nužno je prikupljene kvantitativne informacije adekvatno obraditi i prevesti u kvalitativnu domenu. Takve informacije se rangiraju i koriste kao ulazne vrijednosti za agregacijski proces. Ukoliko dođe do pojave pogreške u ovoj fazi, pogreška će u ovisnosti o individualnoj težini atributa utjecati na konačnu ocjenu. Ukoliko bi se prikupljanje informacija i procjenjivanje stanja provodilo kontinuirano ili u pravilnim vremenskim intervalima, tada postoji dovoljno informacija da se stanje trafostanice prikaže kao funkcija vremena. Na osnovu analize takve vremenske funkcije, bilo bi moguće donositi odluke vezane uz održavanje. U slučajevima gdje je stanje tehničkog sustava opisano uz pomoć vremenske funkcije i odgovarajuće baze znanja moguće je predvidjeti situacije pogodne za pojavu kvara. Ovime se značajno smanjuje mogućnost pojave kvarova s teškim posljedicama po stanje sustava. Donja granica stanja sustava pri kojoj još nije nužna intervencija, ali bi se trebalo pristupiti pripremi održavanja postrojenja dana je ocjenom dostatno, tj. kako se ukupna ocjena sustava smanjuje odnosno približava unaprijed definiranoj donjoj vrijednosti, potrebno je započeti s pripremama oko održavanja komponenti s najlošijim stanjem i održavanje provesti prije nego ocjena sustava padne na vrijednost nedovoljan, odnosno prije nego ukupna ocjena sustava padne ispod dozvoljene kritično niske razine. Kritičnim dijelovima sustava mogu se pridijeliti visoki težinski koeficijenti tako da se njihovo eventualno loše stanje odražava na ukupno stanje sustava.

Primjer procjene stanja energetskog transformatora pokazuje složenost izračuna i agregacijskog postupka. Prikazan je utjecaj nepotpunih procjena osnovnih atributa na opće atribute i konačnu ocjenu stanja. Vidljiv je utjecaj težina pojedinih atributa na agregacijski proces. Na prikazanom primjeru vidljiv je značaj sustava za udaljeni

nadzor i prikupljanje podataka te nadopuna na taj način prikupljenih podataka podacima prikupljenim mjerenjem i redovitim pregledima objekta. Uz pomoć ovakvog alata moguć je uvid u trenutno stanje objekta, degradaciju stanja za i nakon određenog vremena eksploatacije i popravaka odnosno poboljšanje stanja nakon postupka održavanja. Moguće je uočiti kako i u kojoj mjeri pojedini postupci održavanja utječu na stanje promatranog sustava i dostupna je mogućnost održavanja stanja sustava na određenoj kvalitativnoj razini utjecajem na stanje različitih osnovnih atributa.

9.3. Predviđanje

Osim procjene stanja sustava u radu je detaljno opisan alat za predviđanje budućeg stanja na osnovu postojećih podataka. Za ispravnost predviđanja nužna je dostupnost relevantnih podataka. Opisani algoritam za predviđanje zasniva se na teoriji sivih sustava i može se koristiti za predviđanja zasnovana na podacima prikupljenim u jednolikom i nejednolikim vremenskim intervalima uz prethodnu prilagodbu ulaznih vrijednosti.

U Republici Hrvatskoj je trenutno kao model za održavanje energetske sustava u uporabi model periodičkog održavanja s određenim varijacijama [23], [27]. To znači da se prema unaprijed utvrđenim planovima, najčešće godišnjim, trogodišnjim ili šestogodišnjim provodi pregled, reparacija ili zamjena određenog dijela sustava. Ovakav pristup ima određene prednosti poput visokog stupnja raspoloživosti sustava, ali i mane poput visoke cijene održavanja, neadekvatnog iskorištavanja resursa komponente. Također u periodičkom pristupu održavanju ne postoji uvid u trenutno stanje postrojenja niti je moguće dobiti povratnu informaciju nakon provođenja postupka održavanja.

9.4. Daljnji razvoj predloženog modela

Daljnji razvoj predloženog modela mogao bi ići u smjeru poboljšanja organizacije prikupljanja podataka, stavljanju većeg naglaska na kontinuirao mjerenje i prikupljanje podataka te ugradnje algoritama za analizu, procjenu stanja i predviđanje u same promatrane objekte. Kako većina modernih uređaja unutar energetske postrojenja posjeduje određenu količinu ugrađene mjerne opreme (eng. *embedded systems*) i

dijagnostike, dogradnja ovakvih algoritama i povezivanje s opremom za daljinsko prikupljanje podataka trebao bi biti izvediv zadatak. Nadogradnja postojećeg sustava za prikupljanje podataka izvodila bi se proširenjem postojeće aplikacije s modulom za procjenu stanja i modulom za predviđanje budućih stanja.

10. ZAKLJUČAK

U suvremenom svijetu tehnike i ekonomije eksploatacija i održavanje postrojenja sve je složenije i odgovornije, a tehnički sustavi integrirani su u sve društvene i gospodarske procese i njihovo je pravilno funkcioniranje presudan uvjet svakodnevnih ljudskih aktivnosti.

10.1. Model održavanja tehničkih sustava procjenom stanja

Analize eksploatacije postrojenja su pokazala da najveći dio radnih sredstava i opreme ne gubi svoje karakteristike odjednom već da je to kontinuirani proces. U najvećem dijelu slučajeva, oštećenja, kvarovi i havarije u postrojenjima rezultat su postepenog trošenja za vrijeme eksploatacije. Nagovještaj mogućeg kvara pojavljuje se znatno ranije. Za prepoznavanje stanja koje prethodi kvaru potrebno je posjedovati odgovarajuće metode, postupke i opremu za mjerenja odgovarajućih parametara, koji ukazuju na pojavu odstupanja od normalnog rada i nazivnih svojstava sustava.

Posebno su ova tehnička pitanja značajna u elektroenergetskom sustavu (EES) koji predstavlja vrlo složeni tehnički sustav s infrastrukturnim značajem za cjelokupno gospodarstvo, javne službe i cjelokupno stanovništvo na području svake države.

U ovom je radu razmatran model održavanja tehničkih sustava procjenom stanja i prikazan je prijedlog primjene modela na održavanje energetske transformatora, a sve na osnovu recentne literature i uvida u ponašanje energetske postrojenja u praksi. Analizom postojećih modela održavanja uočene su prednosti održavanja prema stanju te je predložen model i opisani postupci, metode i algoritmi potrebni za primjenu predloženog modela održavanja u praksi.

10.2. Potvrde postavljenih hipoteza doktorske disertacije

Provedeno istraživanje je afirmativno pokazalo tj. potvrdilo postavljene dvije hipoteze:

a) Stanje složenog tehničkog sustava moguće je adekvatno predstaviti jednom numeričkom vrijednošću (ili uređenim skupom vrijednosti) koja predstavlja kvalitativnu ocjenu stanja sustava i na osnovu te ocjene imati uvid u stanje sustava.

b) Moguće je na osnovu izvršenih procjena stanja sustava u n vremenskih točaka procijeniti stanje sustava u $n+1$ točki.

Na osnovu teorijskih razmatranja i empirijskih istraživanja konceptualno je definiran predloženi model primjene održavanje procjenom stanja te metoda predviđanja temeljena na teoriji sivih sustava.

10.3. Poboljšani model održavanja procjenom stanja

U razvoju ovog, predloženog, modela održavanja procjenom stanja konzultirani su eksperti i održavatelji elektroenergetskih sustava i postrojenja čija su iskustva bila vrlo korisna i u nekim elementima ugrađena u predložene metode i postupke. Predloženi model moguće je lako adaptirati za primjenu u postrojenjima drugih tehničkih i tehnoloških okvira.

Prvi korak u modelu održavanja tehničkih sustava procjenom stanja je dekomponiranje sustava i određivanje parametara bitnih za pravilan rad određenog postrojenja.¹

Nakon što je sustav dekomponiran, odnosno odabrani bitni parametri za ispravan rad postrojenja, pristupa se: (a) mjerenju fizikalnih veličina, (b) pregledima i (c) prikupljanju podataka iz ugrađene mjerne opreme u samom objektu. Izmjerene vrijednosti uspoređuju se s dopuštenim vrijednostima za svaki parametar i uz pomoć utvrđenih metoda moguće je dati kvalitativnu ocjenu za svako promatrano svojstvo odnosno osnovni atribut promatranog tehničkog sustava.² Oblik i značenje ocjena definirano je u četvrtom poglavlju i takve ocjene predstavljaju ulazne veličine za agregacijski postupak.³

Agregacijski postupak provodi se na osnovu poboljšanog algoritma evidencijskog zaključivanja koji predstavlja način da se: (a) objektivno uvažava težine pojedinih osnovnih atributa, (b) njihov utjecaj na opće atribute i ukupnu procjenu te (c) nesigurnost same ulazne ocjene.

Nakon provedenog agregacijskog postupka dolazi se do konačne ocjene stanja promatranog objekta koja se prikazuje kao distribucija vjerojatnosti svih ulaznih

¹ Upute za pravilnu dekompoziciju sustava dane su u drugom poglavlju ovoga rada, a pravilna primjena postupka najviše ovisi o samoj prirodi tehničkog sustava i tehničkim znanjima iskustvu eksperta koji obavlja procjenu.

² Metoda utvrđivanja kvalitativnih ocjena opisana je u šestom poglavlju ovoga rada.

³ Oblik i značenje kvalitativnih ocjena definirani su u četvrtom poglavlju ovoga rada.

ocjena.⁴ Ovakav način prikaza je prilično složen pa se za međusobnu usporedbu stanja promatranog objekta koristi ukupna konačna ocjena predstavljena jednom numeričkom vrijednošću i intervalom raspršenja konačne ocjene.

Predloženi model održavanja procjenom stanja prikazan je na primjeru energetskog transformatora. Na tome primjeru mogu se uočiti sve prednosti ovog modela kao i složenost proračuna koju unose težinski koeficijenti i nesigurnost u procjeni osnovnih atributa.⁵

Prikazani algoritam sivog predviđanja pogodan je za predviđanje temeljeno na malom broju ulaznih podataka i može se primjenjivati na podacima koji su prikupljeni u jednolikim i nejednolikim vremenskim intervalima.

Na osnovu rezultata agregacijskog procesa i primjene postupka predviđanja dobiva se jasan uvid u: (a) trenutno i (b) predviđeno stanje sustava te se na osnovu tih informacija mogu donijeti odluke o daljnjoj eksploataciji ili održavanju sustava.

Naš poboljšani algoritam evidencijskog zaključivanja može se na adekvatan način nositi i s nepotpunim informacijama o osnovnim ili općim atributima, što je bitno svojstvo koje omogućava uvid u utjecaj nepotpunog poznavanja informacije vezane uz osnovni atribut na ukupnu nesigurnost u procjeni cjelokupnog tehničkog sustava. Podrazumijeva se da nesigurnost konačne ocjene mora biti u razumnim granicama da bi ukupna procjena sustava imala smisla. Također, moguće je prikazati rezultat procjene stanja kao jednu numeričku vrijednost s intervalom od minimalne do maksimalne vrijednosti umjesto procjene koja je raspodijeljena između više unaprijed definiranih ocjena. Takva numerička vrijednost omogućava jednostavan uvid u stanje sustava i usporedbu stanja promatranog sustava s drugim sličnim sustavima ili sa stanjem istog tehničkog sustava u drugom vremenskom trenutku.

Poseban naglasak dan je na pravilnu interpretaciju fizikalnih veličina dobivenih mjerenjima na parametrima sustava. Nužno je prikupljene kvantitativne informacije adekvatno obraditi i prevesti u kvalitativnu domenu. Takve informacije se rangiraju i koriste kao ulazne vrijednosti za agregacijski proces.

Ukoliko se prikupljanje informacija i procjenjivanje stanja provodi kontinuirano ili u pravilnim vremenskim intervalima, tada postoji dovoljno informacija da se stanje

⁴ Agregacijski postupak opisan je u poglavljima četiri i pet ovoga rada.

⁵ U poglavlju osam ovoga rada prikazan je algoritam za predviđanje budućeg stanja na osnovu postojećih podataka.

promatranog objekta prikaže kao funkcija vremena. Na osnovu analize takve vremenske funkcije, moguće je donositi odluke vezane uz održavanje. U slučajevima gdje je stanje tehničkog sustava opisano uz pomoć vremenske funkcije i odgovarajuće baze znanja moguće je predvidjeti situacije pogodne za pojavu kvara. Ovime se značajno smanjuje mogućnost pojave kvarova s teškim posljedicama po stanje sustava. Donja granica stanja sustava pri kojoj još nije nužna intervencija, ali bi se trebalo pristupiti pripremi održavanja postrojenja dana je ocjenom dostatno, tj. kako se ukupna ocjena sustava smanjuje odnosno približava vrijednosti 0.35 potrebno je započeti s pripremanjima oko održavanja komponenti s najlošijim stanjem i održavanje provesti prije nego ocjena sustava padne na vrijednost nedovoljan, odnosno prije nego ukupna ocjena sustava padne ispod dozvoljene kritično niske razine. Kritičnim dijelovima sustava mogu se pridijeliti visoki težinski koeficijenti tako da se njihovo eventualno loše stanje učinkovitije odražava na ukupno stanje sustava.

10.4. Znanstveni doprinosi istraživanja i dalji razvoj predloženog modela održavanja

Tri su znanstvena doprinosa **ovog istraživanja**:

- a) Prijedlog modela stanja energetskog transformatora prilagođen održavanju procenom stanja na temelju prikupljenih podataka.
- b) Određivanje stanja sustava kao funkcije vremena i uvjeta eksploatacije primjenom agregacijskog postupka
- c) Predviđanje stanja sustava na osnovu izvršenih procjena uporabom teorije sivih sustava.

Daljnji razvoj predloženog modela mogao bi ići u smjeru poboljšanja organizacije prikupljanja podataka, stavljanju većeg naglaska na kontinuirao mjerenje i prikupljanje podataka te ugradnje algoritama za analizu ulaznih podataka, procjenu stanja i predviđanje u same promatrane objekte. Kako većina modernih uređaja unutar energetskih postrojenja posjeduje određenu količinu ugrađene mjerne opreme (eng. *embedded systems*) i dijagnostike, dogradnja ovakvih algoritama i povezivanje s opremom za daljinsko prikupljanje podataka trebao bi biti izvediv zadatak.

LITERATURA

- [1] Aihua, L., *A Method for Condition Evaluation Based on DSmT*, Information Management and Engineering (ICIME), 2010 The 2nd IEEE International Conference on, p.p. 263-266, April 16-18, 2010.
- [2] Arshad, M., Islam, S. M., *Power Transformer Condition Monitoring and Assessment for Strategic Benefits*, Proceedings of the Australasian Universities Power Engineering Conference, Christchurch, New Zealand, 28 September - 1 October, 2003.
- [3] Banović, M., *Sustav motrenja energetske transformatora*, Sveučilište u Zagrebu, Fakultet Elektrotehnike i računarstva, Zagreb, 2007. (magistarski rad)
- [4] Barbera F., Schneider H., Kelle P., *A Condition Based Maintenance Model with Exponential Failures and Fixed Inspection Intervals*, Journal of the Operational Research Society, Vol. 47, No. 8 (Aug., 1996) , pp. 1037-1045
- [5] Belić, F., Ševerdija, D., Hocenski, Ž., *Naive Matrix Multiplication Versus Strassen Algorithm in Multi-Thread Environment*, Tehnički vjesnik: znanstveno-stručni časopis tehničkih fakulteta Sveučilišta u Osijeku. **18** (2011) , 3; 309-314 (članak, znanstveni).
- [6] Belton V., Stewart T. J., *Multiple Criteria Decision Analysis: An Integrated Approach*, Norwell, MA: Kluwer, 2002.
- [7] Bengtsson, M., *Condition Based Maintenance System Technology – Where is Development Heading?* Euromaintenance 2004 – Proceedings of the 17th European Maintenance Congress, 11th – 13th of May, 2004, AMS (Spanish Maintenance Society), Barcelona, Spain, B-19.580-2004.
- [8] Bengtsson, M., *Condition Based Maintenance Systems – An Investigation of Technical Constituents and Organizational Aspects*, Mälardalen University Sweden, Vol. 4, Issue 1, No. 36, 2004.
- [9] Bengtsson, M., Olsson, E., Funk P., Jackson, M., *Technical Design of Condition Based Maintenance System-A Case Study using Sound Analysis and Case-Based Reasoning*, Maintenance and Reliability Conference – Proceedings of the 8th Congress, May 2nd – 5th, 2004, Knoxville, USA.

- [10] Bengtsson, M., *Standardization Issues in Condition Based Maintenance*, COMADEM, 2003 Proceedings of the 16th International Congress, August 27-29, 2003, pp. 651-660.
- [11] Bhujanga Rao, *Condition Based Maintenance for Improving PowerPlant Economics*, Naval science & technological laboratory, Visakhapatnam-530 027, India.
- [12] Bing. Z., Lianghua, X., Qiang, M., Bo, W., *Design and Implementation of Equipment Health Management System*, CNKI Journal, Computer Measurement and Control, 2010-05, 2010.
- [13] Blažević, D., Slavek, N., Pešut, M., *Management Application for Distributed Production System Environment*, Machine Engineering. 5 (2005) , 3-4; 173-180 7
- [14] Blažević, D. *Model održavanja opreme procjenom stanja u raspodijeljenom proizvodnom okolišu*, Sveučilište Josipa Jurja Strossmayera u Osijeku, Elektrotehnički Fakultet Osijek, 2006. (magistarski rad)
- [15] Blažević, D., Jović, F., Lukačević, I., *Complex Data Analysis in Condition Based Maintenance*, Machine engineering, 2005.
- [16] Bond, J. *Predictive Engineering for Aging Infrastructure*, , SPIE 3588, 2-13 (1999).
- [17] Buchanan, B. G., Shortliffe E. H., *Rule – Based Expert Systems*, Reading, MA: Addison-Wesley, 1984.
- [18] Bunks, C., McCarthy D., and Al-Ani T., *Condition-Based Maintenance of Machines Using Hidden Markov Models*, Mechanical Systems and Signal Processing, Volume 14, Issue 4, July 2000, Pages 597-612
- [19] Butcher, S. W. *Assessment of Condition-Based Maintenance in the Department of Defense*, Logistics Management Institute, USA, McLean, VA, 2000, pp. 1-70, (2003-10-08).
- [20] Cao, G., Xing, J., Tu, G., *Grey method with use of an analytic hierarchy process for performance evaluation of flue gas desulfurization technology*, CNKI Journal, Proceedings of the CSEE, 2006-04, 2006.
- [21] Car, S., Poljak, M., *Društvo kapitala usmjereno na inovacije za tržište*, Gospodarstvo i održivost. 6 (2010) , 21; 14-15 (članak, stručni).

- [22] Chang, N. B., Chen, H. W., Chen, Y. L., *The Deveopment and Application of Grey Fuzzy Prediction Model*, 1st National Conference of Grey Theory and Applications, p.p. 199-203, October 1996.
- [23] Chang, W. C., Chang, H. L., *The Study of FM(1,1) Model Toolbox*, 3rd National Conference of Grey Theory and Applications, p.p. 127-132, November 1998.
- [24] Chao, W. C., *Grey Model Application for Predicting Industry Growth in Taiwan's free-trade-zone*, Master Thesis, Fengchia University, 2003.
- [25] Chen, D., Trivedi K.S., *Optimization for condition-based maintenance with semi-Markov decision process*, Reliability Engineering & System Safety, Volume 90, Issue 1, October 2005, Pages 25-29
- [26] Chen, J. L., Wen, J. C., Wen, J. H., Wen, K. L., *Study on The Non-Equigap (GM(1,1) modeling*, 4th National Conference of Grey Theory and Applications, p.p. 217-224, October 1999.
- [27] Ciarapica, F. E., Giacchetta, G., *Managing the condition-based maintenance of a combined-cycle power plant: An approach using soft computing techniques*, Journal of Loss Prevention in the Process Industries, Volume 19, Issue 4, July 2006, Pages 316-325
- [28] Davies, A., *Handbook of Condition Monitoring*, Chapman & Hall, Cornwall, 1998.
- [29] Deng, J. L., *Control problems of grey system*, System & Control Letters, (5), 288-294, 1982.
- [30] Deng, J. L., *Introduction of Grey System*, Journal of Hrey System, Vol. 1, p.p. 1-24, 1989.
- [31] DiGiorgio, J. B., *Dissolved Gas Analysis of Mineral Oil Insulating Fluids*, DGA Expert System: A Leader in Quality, Value and Experience 1, 1-17, 2005.
- [32] Discenzo, F. M., *Self-diagnosing intelligent motors: a key enabler for next generation manufacturing systems*, "IEE Colloquium on Intelligent and Self-Validating Sensors", UK, Oxford, 1999, pp. 3/1-3/4.
- [33] Dong, Y., Gu, Y., Yang, Kun., Zhang, W., *A Combining Condition Prediction Model and its Application in Power Plant*, Machine Learning's and Cybernetics, 2004

Proceedings of 2004 International Conference on, Vol. 6, p.p. 3474-3478, August 24-26, 2004.

[34] Eisenmann, R. C. and Eisenmann, R. C. JR., *Machinery Malfunction Diagnosis and Correction*, Prentice-Hall, Inc., Saddle River, New Jersey (1998).

[35] Fei, S., Sun, Y., *Forecasting dissolved gases content in power transformer oil based on support vector machine with genetic algorithm*, Electrical Power System Research, Vol. 78, p.p. 507-514, March 2008.

[36] Furčić, M., Lončar, M., Maras, I., Meštrović, K., Mik, A., Poljak, M., Vidović, M., Šojat, Z., *Sustav monitoringa visokonaponskog rasklopnog postrojenja - razvoj, montaža i probni rad*, Referati, 9. savjetovanje HRO CIGRE = 9th HRO CIGRE Session, Cavtat, 8.-12. studenoga 2009. Zagreb: HRO CIGRE, 2009. 9 str. (predavanje, domaća recenzija, objavljeni rad, stručni)

[37] Garga, A. K., McClintic, K.T., Campbell, R.L., Chih-Chung Yang, Lebold, M.S., Hay, T.A., Byington, C.S., *Hybrid Reasoning for Prognostic Learning in CBM Systems*, Aerospace Conference Proceedings, USA, Big Sky, MT, 2001, pp. 6-2957-6-2969. 17

[38] Guoqing, Y. B. G. J T, *Method of Predicting the Gas-in-oil Concentrations in Transformers Based on Grey Theory [J]*, CNKI Journal, Proceedings of The Csu-epsa, 2001-03, 2001.

[39] Hai-Quan, F., Gabbar, H. A., Suzuki, K., Datu, R., *Use of Grey Relation Analysis in Causative Analysis of Chemical Plant Accidents*, Advanced System Safety Laboratory, Department of Systems Engineering, Okayama, Japan, Vol. 2, paper 4, p.p. 341-350, October 2006.

[40] Handschin, E., Jürgens, I., Weller, J., Zdrallek, M., *Novel Methods for the Condition Based Maintenance of Distribution Networks*, Power Tech, 2007 IEEE Lausanne, July 1-5, 2007, p.p. 6-11.

[41] Harrison, P. J., Stevens, C. F., *A Bayesian approach to short-term forecasting*, Operational Research Quarterly (1970-1977), Palgrave Macmillan Journals, Vol. 22, No. 4, p.p. 341-362, December 1971.

[42] Huang C. L., Yoon K., *Multiple Attribute Decision Making Methods and Applications*, A State-of-Art Survey, New York: Springer-Verlag, 1981.

- [43] Huang, S., Li, J., Xhen, F., *The Development of Condition-based Maintenance in Chinese Thermal Power Plants [JJ]*, CNKI Journal, Turbine Technology, 2007-04, 2007.
- [44] Hvass, P. B., Tesar, D., *Condition Based Maintenance For Intelligent Electromechanical Actuators*, Mechanical Engineering Department, The University of Texas at Austin, Austin, TX 78712, 2004
- [45] Ivanović, M., Keser, T., Blažević, D., *Capitalization of knowledge - innovation processes in transitional countries*, Tehnički vjesnik: znanstveno-stručni časopis tehničkih fakulteta Sveučilišta u Osijeku. **18** (2011) , 1; 15-22 (članak, znanstveni).
- [46] Jagnjić, Ž., Slavek, N., Blažević, D., *Condition Based Maintenance of Power Distribution System*, The 5th EUROSIM Congress on Modeling and Simulation, ESIEE, Paris, 2004. 19
- [47] Jaman, N., Poljak, M., Šomodić, P., Knez, N., *Otkrivanje deformacije namota energetskog transformatora ispitivanjem na terenu i njegov popravak*, 2. savjetovanje HK CIGRE - lekcija I: Oprema, Velebir, V. (ur.). Zagreb, 1995. 105-111 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
- [48] Jardine, A.K.S., Banjevic D., Makis V., *Optimal replacement policy and the structure of software for condition-based maintenance*, Journal of Quality in Maintenance Engineering, Jun 1997 Volume: 3 Issue: 2 Page: 109 – 119
- [49] Jardine, A.K.S., Joseph, T., Banjevic D., *Optimizing condition-based maintenance decisions for equipment subject to vibration monitoring*, Journal of Quality in Maintenance Engineering, Sep 1999 Volume: 5 Issue: 3 Page: 192 – 202
- [50] Jarrell, D., Sisk, D., Bond, L. *Prognostics and Condition Based Maintenance (CBM) A Scientific Crystal Ball*, Pacific Northwest National Laboratory, Richland, WA 99352
- [51] Jiaping, Y., Jian, Z., Zanwei, W., *Production Performance and its Controlling Factors in the Panhe CMB Gas Field*, Southern Quinshui Basin, CNKI Journals, Natural Gas Industry, 2011-05, 2011.
- [52] Jiang, G., Liu, S., *Application of Grey System in the Coastline Forecasting of Sub-huanghe Delta*, International Conference on Estuaries and Coasts, Hangzhou, China, November 9-11, 2003.

- [53] Jovic, F., Filipovic, M., Blazevic, D., Slavek, N., *Condition Based Maintenance in Distributed Production Environment*, Machine engineering, 2004.
- [54] Jović, F., Krmpotić, D., Jović, A., Jukić, M., *Evaluation of Grey Prediction Method of Energy Consumption*, MIPRO 2005, Budin, L., Ribarić, S. (ur.). Rijeka: Croatian Society for Information and Communication Technology, 2005. 64-67 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
- [55] Jović, F., Krmpotić, D., *Prediction of Short-term Electrical Energy Consumption in Ceramic Industry*, Computer integrated manufacturing: proceedings of the International conference CIM 2001. Warszawa: Wydawnictwa Naukowo-Techniczne, cop., 2005. 88-97 (poster, međunarodna recenzija, objavljeni rad, znanstveni).
- [56] Jović, F., Slavek, N., Blažević, D., *Development of a Model and Simulation in Decision Making Process*, Recent Advances in Intelligent Systems and Signal Processing, Mastorakis, N.E., Manikopoulos, C., Antoniou, G.E., Mladenov, V.M., Gonos, I.F. (ur.). Krf, Grčka: WSEAS Press, 2003. Str. 271-275.
- [57] Jović, F., Slavek, N., Blažević, D., *Reinforcement Learning in Non-Markov Conservative Environment Using an Inductive Qualitative Model*, International Journal on Artificial Intelligence Tools (IJAIT). 20 (2011) , 5; 887-909 (članak, znanstveni).
- [58] Jukić M.. *Inteligentno prilagodljivo vođenje procesa pomoću sivih modela*, Sveučilište Josipa Jurja Strossmayera u Osijeku, Elektrotehnički Fakultet Osijek, 2007. (doktorska disertacija).
- [59] Keeney, R. L., Raiffa, H., *Decision With Multiple Objectives*, U.K. : Cambridge Univ. Press, 1993.
- [60] Keitoue, S., Keller, A., Murat, I., Mikulecky, A., Poljak, M., *Sustav motrenja energetske transformatora u distribucijskim mrežama*, Prvo savjetovanje Hrvatskog ogranka Međunarodne elektrodistribucijske konferencije, Šibenik, 18.-21.05.2008., HO CIRED, Zdenko Tonković (ur.). Zagreb: Hrvatski ogranak Međunarodne elektrodistribucijske konferencije, 2008. SO1-14, 1-8 (predavanje, domaća recenzija, objavljeni rad, stručni).
- [61] Kohler, J. L., Sottile, J., Trutt, F. C., *Condition Based Maintenance of Electrical Machines, Industry Applications Conference*, 1999. Thirty-fourth IAS Annual Meeting, Conference Record of the 1999 IEEE, Vol. 1., p.p. 205-211.

- [62] Kong, J., Wu, L., Li, X., Yuan, J., *A Transformer Condition Assessment System Based on Data Warehouse and Data Mining*, Computational Science – ICCS 2007, Vol. 4488/2007, p.p. 978-981, 2007.
- [63] Koochaki, J., *Colaborative Learning in Condition Based Maintenance*, Proceedings of the World Congress on Engineering 2009, WCE 2009, London, U.K, Vol. 1, July 1 - 3, 2009.
- [64] Lee, K. Y., Cha, Y.T., Park, Y. H., *Short-term load forecasting using an artificial neural network*, IEEE Transactions on Power Systems, Vol. 7, Issue 1, p.p. 124-132, February 1992.
- [65] Lewand, L. R., Griffin, P., *Condition Assessment of Oil Circuit Breakers and Load Top-Changers by the Use of Laboratory Testing and Diagnostics*, Chemist Perspective, Summer 2004.
- [66] Li, H., Yan, Z., *Condition-Based Monitoring and Maintenance of Oil-Immersed Transformer [J]*, CNKI Journal, Electrical Equipment, 2003-05, 2003.
- [67] Lindgren, S., *Power Transformer Asset Management On-Line DGA - The New Ballgame*, EPRI Substation Equipment Diagnostics Conference XI, New Orleans, Louisiana, February 23-26, 2003.
- [68] Lopez de Mantaras, R., *Approximate Reasoning Models*, Chichester, U. K.: Ellis Horwood Ltd., 1990.
- [69] Majdandžić, N., *Strategije održavanja i informacijski sustavi održavanja*, Udžbenik Strojarskog fakulteta u Slavonskom Brodu Sveučilišta u Osijeku, Slavonski Brod, 1999.
- [70] Mann, L., Saxena A., Knapp, G. M., *Statistical-based or condition-based preventive maintenance?*, Journal of Quality in Maintenance Engineering, Mar 1995 Volume: 1 Issue: 1 Page: 46 – 59
- [71] Marseguerra, M., Zio, E., Podofillini, L., *Condition-based maintenance optimization by means of genetic algorithms and Monte Carlo simulation*, Reliability Engineering and System Safety, v 77, n 2, Aug 1, 2002, p 151-166 29
- [72] Mathew, A., Zhang, S., Ma, L., Earle, T., Hargreaves, D., *Reducing maintenance cost through effective prediction analysis and process integration*, Advances in Vibration Engineering 5(2):p.p. 87-96, 2006.

- [73] Meštrović, K., Poljak, M., Vidović, M., Furčić, M., Lončar, M., Maras, I., Mik, A., *New Concept Of High-Voltage Switchgear On-line Monitoring System*, 16th International Symposium on High Voltage Engineering – ISH 2009, South Africa, Cape Town, 24 – 28 August 2009. (predavanje, međunarodna recenzija, objavljeni rad, stručni).
- [74] Mitchell, J. S., *Five to ten year vision for CBM, ATP Fall Meeting*, Condition Based Maintenance Workshop, USA, Atlanta, GA, 1998.
- [75] Mu, H., Kondou, Y., Tonooka, Y., Sato, Y., Zhou, W., Ning, Y., Sakamoto, K., *Grey Relative Analysis and Future Prediction on Rural Household Biofuels Consumption in China*, Fuel Processing Technology 85 (2004), p.p. 1231-1248.
- [76] Paoletti, G., Baier, M., *Failure Contributors of MV Electrical Equipment and Condition Assessment Program Development*, IEEE Transaction on Industry Applications, Vol. 38, Issue 6, p.p.1668-1676, November/December 2002.
- [77] Papalexopoulos, A. D., Hesterberg, H.C., *A regression-based approach to short-term system load forecasting*, IEEE Transactions on Power Systems, Vol. 5, Issue. 4, p.p. 1535-1547, November 1990.
- [78] Pei, G., Deng, X., *Application of Time Series' Equal-space GM(1,1) on Slope Displacement Prediction*, Proceedings of 2011 International Symposium – Geospatial Information Technology and Disaster Prevention and Reduction, ISBN 978-0-646-55611-6, May 2011.
- [79] Poljak, M., Gazivoda, S., *Metoda frekvencijskog odziva - dijagnostički alat za energetske transformatore*, 6. savjetovanje HK CIGRE, Transformatori, grupa A2, Tomiša, Irena (ur.) Zagreb: Hrvatski komitet CIGRE, Zagreb, 2003. 59-68 (predavanje, domaća recenzija, objavljeni rad, stručni).
- [80] Pudlo, G., Tenbohlen, S., Linders, M., Krost, G., *Integration of Power Transformer Monitoring and Overload Calculation into the Power System Control Surface*, IEEE/PES Transmission and Distribution Conference, Yokohama, 2002.
- [81] Rao, B. K. N., *Handbook of Condition Monitoring*, Elsevier Science LTD., 1996.
- [82] Schönberger, M., *Preventivna kontrola energetskih transformatora*, HEP d.d., Direkcija za prijenos, 2000. (pripravnički rad)

- [83] Setayeshmehr, A., Akbari, A., Borsi, H., Gockenbach, E., *A procedure for diagnosis and condition based maintenance for power transformers*, IEEE International Symposium on Electrical Insulation, 2004, p 504-507
- [84] Shafer G., *Mathematical Theory of Evidence*. Princeton, NJ; Princeton Univ. Press, 1976.
- [84] Shuhong, L. J. H., *Improvement of grey model to forecast the transformer faults [J]*, Kybernetes, Journal of Huazhong University of Science and Technology, 2008-05, 2008.
- [86] Slavek, N., Grgić, T., Blažević, D., *Assessment of the Software Process*, Proceedings of the International Conference on Information Technologies (InfoTech-2007), Volume 2, Systems for Automation of Engineering and Research (SAER), Assoc. Prof. Dr. Radi Romansky (ur.). Sofia: SAER Forum Group (Technical University Sofia), 2007. 33-40 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
- [87] Slavek, N., Jović, F., Blažević, D., *Quality Factors for the Real-Time Embedded And Safety-Critical Software Systems*, The 5th EUROSIM Congress on Modeling and Simulation, Marne la Vallee : ESIEE groupe, 2004.
- [88] Slavek, N., Jović, F., Blažević, D., *Toward Software Process and Software Product Quality Integration*, International Conference on Computer Aided Design and Manufacturing, CADAM 2007, Prof. Boris Obsiger, Dr. Sc. (ur.). Rijeka: ZIGO Rijeka, 2007. 87-88 (predavanje, međunarodna recenzija, objavljeni rad, znanstveni).
- [89] Slavek, N., Nenadić, K., Blažević, D., *Software Quality Metrics System (SQMS)*, Proceedings of the 10th International Conference on The Modern Information Technology in the Innovation Processes of the Industrial Enterprises, MITIP 2008, Jan Han, Pavla Holejsavska (ur.). Pilsen, Čehoslovačka: Bily slon, s.r.o. Press, Pilsen Čehoslovačka, 2008. 334-339 (predavanje, međunarodna recenzija, objavljeni rad).
- [90] Slišković, D. Grbić, R., Hocenski, Ž., *Methods for Plant Data-Based Process Modeling in Soft-Sensor Development*, Automatika: časopis za automatiku, mjerenje, elektroniku, računarstvo i komunikacije. 52 (2011) , 4; 306-318 (članak, znanstveni).

- [91] Sokolov, V., *Transformers Condition – Based Ranking on the Basis of Design Review and Comprehensive Oil Analysis*, Fourth AVO New Zeland, International Technical Conference, 2005.
- [92] Sokolov, V., *Transformers Condition - Based Ranking*, Fifth AVO New Zeland, International Technical Conference 2006.
- [93] Song, B., Peng, Z., *Short-term forecast of the gas dissolved in power transformer using the hybrid grey model*, Kybernetes, Vol. 38, p.p. 489-496, 2009.
- [94] Song, B., Yu, P., Wen, X., *Fault Diagnosis for Power Transformer Based on Grey Relation Entropy [J]*, CNKI Journal, Automation of Electrical Power Systems, 2005-18, 2005.
- [95] Sturm, F. A., *Efficient Operations, Intelligent Diagnosis and Maintenance*, VGB PowerTech Service GmbH, Essen, Germany, 2003.
- [96] Suprasad, V. A., McLaughlin L., *Optimal Design of a Condition-Based Maintenance Model*, Relx Software Corporation, Greensburg, www.relaxsoftware.com
- [97] The Institute of Electrical and Electronics Engineers, Inc., *IEEE Guide for the interpretation of Gases Generated in Oil-Immersed Transformers*, IEEE Std C57.104™-2008, September 26, 2008.
- [98] Thurston, M. G., *An Open Standard for Web-Based Condition-Based Maintenance Systems*, IEEE Systems Readiness Technology Conference, 2001, USA, Valley Forge, PA, 2001, pp. 401-415.
- [99] Thurston, M., Lebold, M., *Standards Developments For Condition-Based Maintenance Systems*, Applied Research Laboratory, Penn State University, State College, PA 16804-0030
- [100] Tsang, A. H. C., *Condition-Based Maintenance: Tools and Decision Making*, *Journal of Quality in Maintenance Engineering*, Vol. 1, No. 3, 1995, pp. 3-17. 40
- [101] van Rijn, T. G. M., Slangen, J. H. M., de Vries, F. S. W., *Experiences and New Developments with Condition Based Maintenance in Netherlands*, 19th International Conference on Electricity Distribution, Vienna, , p.p. 1-0779, May 21-24, 2007.

- [102] Wang, J., Xu, H., Chen, W., Zhou, J., Yuan, Y., *Grey Situation Decision-Making Method of Condition Based Maintenance Strategy for Power Transformer*, CNKI Journal, Computer Measurement and Control, 2009-18, 2009.
- [103] Wang, M. H., Hung, C. P., *Novel grey model for the prediction of trend of dissolved gases in oil-filled power apparatus*, Electrical Power System Research, Vol. 67, p.p. 53-58, October 2003.
- [104] Wang, W., Christer A. H., *Towards a general condition based maintenance model for a stochastic dynamic system*, University of Salford, Salford, MS 4WT, UK; w.wang@salford.ac.uk
- [105] Wang, W., Scarf, P., Sharp, J., *Modeling condition based maintenance of production plant*, VTT Symposium, 1997, VOL 172, pages 75-84
- [106] Wanling, L., Zhengsheng, W., Yiangjun, S., *Research on Prognostic Method Based on Grey Model*, Computer Science and Electronics Engineering (ICCSEE), 2012 international Conference on, p.p. 366-369, March 2012.
- [107] Wen, K. L., *Grey System: Modeling and Prediction*, Yang's Scientific Press, 2004.
- [108] Wen, K.L., Huang. Y. F., Chang, W. C., *Grey Prediction Model and its Applications*, CWCi Publisher, 2002.
- [109] Williams, J.H., Davies A., Drake, P.R., *Condition-based maintenance and machine diagnostics*, Chapman & Hall, 1994
- [110] Wu, J. H., Wen, K.L., *Rolling Error in GM(1,1) modeling*, Journal of Grey System, Vol. 13, No. 1, p.p. 77-80, 2001.
- [111] Xiao, Y., Chen, X., Zhu, H., *Forecasting of Gas Concentration in Power Transformer Oil Based on Least Square Support Vector Machine [J]*, CNKI Journal, Power System Technology, 2006-11, 2006.
- [112] Yager R. R., *On the Dempster-Shafer framework and new combination rules*, Inf. Sci., 1995, 41/2, 317-323.
- [113] Yam, R. C. M., Tse, P. W., Li, L., Tu, P., *Intelligent Predictive Decision Support System for Condition-Based Maintenance*, International Journal of Advanced Manufacturing Technology, 2001, Vol. 17, Issue 5, pp. 383-391.

- [114] Yang S. K., *A condition-based preventive maintenance arrangement for thermal power plants*, Electric Power Systems Research, Volume 72, Issue 1, 15 November 2004, Pages 49-62
- [115] Yang, J. B., Xu, D. L., *On the evidential Reasoning Algorithm for Multiple Attribute Decision Analysis Under Uncertainty*, IEEE Transactions on Systems, Man, and Cybernetics - part A: Systems and Humans, 2002, 32/3, 289-304.
- [116] Yang, J. B., *Rule and utility based evidential reasoning approach for multiple attribute decision analysis under uncertainty*, Eur. J. Oper. Res., 2001, 131/1, 31-61.
- [117] Yean, C. L., *Grey Prediction of Electricity expenditure in Taiwan*, 1st National Conference of Grey Theory and Applications, p.p. 244-254, October 1996.
- [118] Yen, J., *Generalizing the Dempster – Shafer Theory to Fuzzy Sets*, IEEE Transactions on Systems, Man, and Cybernetics, 1990, 20/3, 559-570.
- [119] You, M. L., Wen, K. L., *The Error Analysis in GM(1,1) model*, Journal of Chinese Grey System, Vol. 3, No. 1, p.p. 63-70, 2000.
- [120] Zealand, C. M., Burn, D. H., Simonović, S. P., *Short term streamflow forecasting using artificial neural networks*, Journal of Hydrology, Vol. 214, Issue 1-4, p.p. 32-48, January 1999.
- [121] Zhang, Z. J., Yang J. B., Xu, D. L., *A hierarchical analysis model for multiobjective decision making*, Analysis, Design and Evaluation of Man-Machine Systems, Oxford, U.K., 1990.
- [122] Zhu, Y., Wu, L., Li, X., Yuan, J., *A transformer condition assessment framework based on data mining*, Power Engineering Society General Meeting, 2005. IEEE, Vol. 2, p.p.1875-1880, June 12-16, 2005.

SAŽETAK

Održavanje prema stanju elektroenergetskog sustava zahtjevan je i složen zadatak. Uključuje donošenje odluka na temelju analize višestrukih atributa. Odluke se donose na temelju podataka koji u sebi sadrže određenu količinu nesigurnosti, kvalitativnih ocjena i numeričkih podataka. Sve podatke, koji se prikupljaju uz pomoć za to posebno namijenjene mjerne opreme, daljinskog očitavanja ili od strane zaposlenika, potrebno je na odgovarajući način pripremiti i pridružiti im odgovarajuće značenje.

U ovom radu predstavljena je višerazinska analiza temeljena na Dampster – Shafer teoriji evidencijskog zaključivanja. Predložena je dekompozicijski model energetskog transformatora i prikazan je način provođenja agregacijskog procesa zasnovanog na evidencijskom zaključivanju. Stanje promatranog objekta predstavlja se distribucijom svih ulaznih ocjena, a može se prikazati i jednom broječanom vrijednošću tj. ukupnom konačnom ocjenom. Predstavljen je algoritam predviđanja temeljen na teoriji sivih sustava GM (1,1) koji uspješno predviđa buduće stanje osnovnog atributa tehničkog sustava na osnovu prijašnjih stanja, a sve na malom skupu poznatih podataka. Prikazana je analiza greške predviđanja i dan je alat za određivanje preciznosti predviđanja. Razvijene su aplikacije temeljene na unaprijeđenom algoritmu evidencijskog zaključivanja i algoritmu sivog predviđanja za GM(1,1) model. Predloženi model, postupak prikupljanja i analize podataka, agregacijski postupak i postupak sivog predviđanja prikazani su na primjeru održavanja energetskog transformatora, kao reprezentativnog tehničkog sustava.

Ključne riječi: održavanje prema stanju, energetski transformator, evidencijsko zaključivanje, model sivog sustava, sivo predviđanje, kvalitativna i kvantitativna analiza

ABSTRACT

Condition Based Maintenance (CBM) is part of the “on demand” response of the plant. Unlike other plant responses it contains a large amount of uncertain information, qualitative and numerical data. Distributed unmanned plants like electric power distribution network, power grids and power transformers add to this task the demand for possibly uninterrupted users’ service.

A multilevel condition evaluation framework based on evidential reasoning algorithm is proposed. A model for condition based maintenance of power transformer and procedures for aggregation process based on evidential reasoning are presented. Calculus apparatus for Condition state assessment of monitored object is described. Gray system theory forecast algorithm for dissolved gas analysis prediction and its application are presented and elaborated. Software applications for evidential reasoning aggregation and GM(1,1) model gray forecasting are developed.

Results of CBM decomposition, evidential reasoning algorithm analysis and gray forecast of power transformer condition state are given.

Keywords: condition based maintenance, power transformer, evidential reasoning, grey system model, gray forecasting, quantitative and qualitative data analysis

ŽIVOTOPIS

Damir Blažević rođen je 7. ožujka 1977. godine u Đakovu gdje je završio osnovnu školu i Opću gimnaziju. Elektrotehnički fakultet Osijek, Sveučilišta J. J. Strossmayera u Osijeku upisuje 1995. g. Za vrijeme studija kao demonstrator sudjeluje u izvođenju nastave iz pet kolegija. Zvanje diplomiranog inženjera elektrotehnike stječe 2001. g. obranom diplomskog rada pod nazivom *"Istraživanje preciznosti i brzine rada Grooverova algoritma"*. Nakon završetka školovanja odlazi na odsluženje vojnog roka. Poslijediplomski znanstveni studij upisuje na Elektrotehničkom fakultetu u Osijeku, gdje i zapošljava kao znanstveni novak 2002. godine. Od tada radi kao istraživač na znanstvenom projektu Ministarstva znanosti *"Inteligentni industrijski sustavi"* i aktivno sudjeluje na više stručnih projekata suradnje s gospodarstvom. Aktivno sudjeluje u kreiranju i izvođenju nastave na Elektrotehničkom fakultetu iz više kolegija. Pohađa stručno usavršavanje po programu CISCO Akademije mrežnih tehnologija u organizaciji CARNET-a i SRC-a u Zagrebu. Godine 2005. dobiva od Elektrotehničkog fakulteta u Osijeku priznanje kao istaknuti mladi znanstvenik. Poslijediplomski magistarski studij završava 2006. godine u zvanju magistar znanosti, znanstveno područje tehničke znanosti, znanstveno polje elektrotehnika.

Stručni ispit iz strukovnog područja elektrotehnike polaže 2006. godine. Član je Hrvatske komore inženjera i arhitekata u graditeljstvu od 2007. godine. Član je tehničkog odbora Hrvatskog zavoda za norme TO E64 Električne instalacije i zaštita od električnog udara, te TO E81 Zaštita od munje. Sudjeluje u izvođenju nastave na dodiplomskom i diplomskom studiju Elektrotehničkog fakulteta Osijek. Instruktor je na Akademiji mrežnih tehnologija i predavač na seminarima za stručno usavršavanje sudionika u gradnji pri ETF-u Osijek. Član je izvršnog odbora Hrvatskog društva održavatelja Osijek.

Objavio je poglavlje u knjizi s koautorima, pet znanstvenih radova u časopisima, pet konferencijskih radova u zbornicima skupova s međunarodnom recenzijom i više drugih konferencijskih radova na skupovima s recenzijom.

PRILOZI

Prilog 1. Osnovni kod aplikacije za procjenu stanja

```
#include <stdio.h>
/*
Algoritam za agregaciju atributa
definicija porebnih varijabli
    broj elemenata za agregaciju,
    brojac,
Funkcija za unos atributa
    - unos broja elemenata L,
    - unos ocjena elementa i stupanj pouzdanosti ocjene svakog elementa
Funkcija za izracun osnovnih tezina
    - to je matica s osnovnim tezinama
Funkcija za izracun kombiniranih tezina
    - f-ija prima matricu osnovnih tezina i i racuna složene tezine
    - izracun m tilda i M
    - poziv funkcije L-1 puta
Funkcija za izracun kombiniranih stupnjeva pouzdanosti
Ispis rezultata

*/
int L;
const float br1=1;
float MBasic[20][6],MCombi[20][6];
float MTBasic[20][3],MTCombi[20][3];
float MCombiDB[1][7];
float w,W[20];

void Utility ()
{
    // izracun utility-a i utility intervala
    float H[6],Umin,Umax,Uavg,sumaBU=0,sumaBU1=0;
    int i;
    H[1]=0;
    H[2]=0.35;
    H[3]=0.55;
```

```
H[4]=0.85;
H[5]=1;
for (i=2;i<=5;i++)
{
    sumaBU=sumaBU+MCombiDB[0][i]*H[i];
}
for (i=1;i<=4;i++)
{
    sumaBU1=sumaBU1+MCombiDB[0][i]*H[i];
}

Umin=(MCombiDB[0][1]+MCombiDB[0][6])*H[1]+sumaBU;
Umax=(MCombiDB[0][5]+MCombiDB[0][6])*H[5]+sumaBU1;
Uavg=(Umax+Umin)/2;
printf ("\nUmin = %f",Umin);
printf ("\nUavg = %f",Uavg);
printf ("\nUmax = %f",Umax);

}

void CombiDB ()
{// izracun combined probability masess
    int j;

    for (j=1;j<=5;j++)
    {
        MCombiDB[0][j]=MCombi[L][j]/(br1-MTCombi[L][1]);
    }

    MCombiDB[0][6]=MTCombi[L][2]/(br1-MTCombi[L][1]);
    for (j=1;j<=6;j++)
    {
        printf ("%0.4ft",MCombiDB[0][j]);
    }
    FILE *dat;
    dat=fopen ("rezultati.txt","a");
    fprintf (dat,"Parametri\n");
    for (j=1;j<=6;j++)
    {
```

```
fprintf (dat, "%.4f\t", MCombiDB[0][j]);
}
fprintf (dat, "\n");
fclose (dat);
}

void Kombinirane ()
{
//izracun kombiniranih tezina tj. matrice MCombi
int i,j,korak;
float K[20],sumaM;
for (j=0;j<=5;j++)
{
    MCombi[1][j]=MBasic[1][j];
    MTCombi[1][j]=MTBasic[1][j];
}
//izracun K
for(korak=1;korak<=L-1;korak++)
{

    sumaM=0;
    for(i=1;i<=5;i++)
    {
        j=1;
        for(j=1;j<=5;)/while((j!=i)&&(j<=5))
        {
            if (j==i) j++;
            sumaM=sumaM+MCombi[korak][i]*MBasic[korak+1][j];
            j++;
        }
    }

    K[korak+1]=br1/(1-sumaM);
    printf("\nK[%d]=%f\n", korak+1,K[korak+1]);

    for(i=1;i<=5;i++)
    {

        MCombi[korak+1][i]=K[korak+1]*(MCombi[korak][i]*MBasic[korak+1][i]+MCombi[korak][i]
        *MTBasic[korak+1][0]+MBasic[korak+1][i]*MTCombi[korak][0]);
    }
}
```

```
MTCombi[korak+1][2]=K[korak+1]*(MTCombi[korak][2]*MTBasic[korak+1][2]+MTCombi[korak][1]*MTBasic[korak+1][2]+MTCombi[korak][2]*MTBasic[korak+1][1]);
MTCombi[korak+1][1]=K[korak+1]*MTCombi[korak][1]*MTBasic[korak+1][1];
MTCombi[korak+1][0]=MTCombi[korak+1][1]+MTCombi[korak+1][2];

//M[korak+1][8]=K[korak+1]*(M[korak][8]*M[korak+1][8]+M[korak][7]*M[korak+1][8]+M[korak][8]*M[korak+1][7]);
//M[korak+1][7]=K[korak+1]*(M[korak][7]*M[korak+1][7]);
printf("\n");
for (i=1;i<=L;i++)
{

    for (j=1;j<=5;j++)
    {
        printf("%.2f\t",MCombi[i][j]);

    }
    printf("%.2f\t",MTCombi[i][1]);
    printf("%.2f\t",MTCombi[i][2]);
    printf("%.2f\t",MTCombi[i][0]);

    printf("\n");
}

}

//ispis kombinirane matrice
printf("KOnacni rezultat\n");
for (i=1;i<=L;i++)
{

    for (j=1;j<=5;j++)
    {
        printf("%.2f\t",MCombi[i][j]);

    }
    printf("%.2f\t",MTCombi[i][1]);
    printf("%.2f\t",MTCombi[i][2]);
    printf("%.2f\t",MTCombi[i][0]);
    printf("\n");
}
```

```
    }
    // ispis rezultata agregacije L atributa
    printf("Konacni rezultat agregacije %d atributa\n",L);
    for (j=1;j<=5;j++)
    {
        printf("%.2f\t",MCombi[L][j]);
    }

    printf("%.2f\t",MTCombi[L][1]);
    printf("%.2f\t",MTCombi[L][2]);
    printf("%.2f\t",MTCombi[L][0]);
    printf("\n");
}

void Osnovne_tezine1 ()
{// izracun matrice osnovnih tezina kada su tezinske vrijednosti atributa jednake
    int i,j;
    float sumaMB;
    printf ("Unesite vjerojatnost da odredjenji atribut ima trazenu ocjenu\n");
    for (i=1;i<=L;i++)
    {
        sumaMB=0;
        for (j=1;j<=5;j++)
        {
            printf("Unesite vjerojatnost za ocjenu %d atributa %d: ",j,i);
            scanf ("%f",&MBasic[i][j]);
            sumaMB=sumaMB+MBasic[i][j];
            MTBasic[i][1]=1-w;
            MTBasic[i][2]=w*(1-sumaMB);
            MTBasic[i][0]=MTBasic[i][1]+MTBasic[i][2];
        }
    }
    //kontrolni ispis matrica
    for (i=1;i<=L;i++)
    {

        for (j=1;j<=5;j++)
        {
            printf("%.2f\t",MBasic[i][j]);
```



```
        }
        printf ("%0.2f\t",MTBasic[i][1]);
        printf ("%0.2f\t",MTBasic[i][2]);
        printf("\n");
    }
    for (i=1;i<=L;i++)
    { // mnozenje matrice osnovnih elemenata s w
        for (j=1;j<=5;j++)
            MBasic[i][j]=w*MBasic[i][j];
    }
    //kontrolni ispis matrica
    printf("\n");
    for (i=1;i<=L;i++)
    {

        for (j=1;j<=5;j++)
        {
            printf ("%0.2f\t",MBasic[i][j]);

        }
        printf ("%0.2f\t",MTBasic[i][1]);
        printf ("%0.2f\t",MTBasic[i][2]);
        printf("\n");
    }

}

void Osnovne_tezine2 ()
{ //izracun tezina za slucaj razlicitih tezina atributa W
    int i,j;
    for (i=1;i<=L;i++)
    {
        printf("Unesite tezinu za atribut (0-1) %d: ",i);
        scanf ("%f",&W[i]);
    }

    // izracun matrice osnovnih tezina kada su tezinske vrijednosti atributa jednake

    float sumaMB;
    printf ("Unesite vjerojatnost da odredjenji atribut ima trazenu ocjenu\n");
    for (i=1;i<=L;i++)
```

```
{    sumaMB=0;
    for (j=1;j<=5;j++)
    {
        printf("Unesite vjerojatnost za ocjenu %d atributa %d: ",j,i);
        scanf ("%f",&MBasic[i][j]);
        sumaMB=sumaMB+MBasic[i][j];
        MTBasic[i][1]=1-W[i];
        MTBasic[i][2]=W[i]*(1-sumaMB);
        MTBasic[i][0]=MTBasic[i][1]+MTBasic[i][2];
    }
}
//kontrolni ispis matrica
for (i=1;i<=L;i++)
{

    for (j=1;j<=5;j++)
    {
        printf("%.2f\t",MBasic[i][j]);

    }
    printf("%.2f\t",MTBasic[i][1]);
    printf("%.2f\t",MTBasic[i][2]);
    printf("\n");
}
for (i=1;i<=L;i++)
{
    // mnozenje matrice osnovnih elemenata s w
    for (j=1;j<=5;j++)
        MBasic[i][j]=W[i]*MBasic[i][j];
}
//kontrolni ispis matrica
printf("\n");
for (i=1;i<=L;i++)
{

    for (j=1;j<=5;j++)
    {
        printf("%.2f\t",MBasic[i][j]);

    }
    printf("%.2f\t",MTBasic[i][1]);
```

```
        printf("%.2f\t",MTBasic[i][2]);
        printf("\n");
    }

}

void Unos_tezina ()
{
    int i;
    for (i=1;i<=L;i++)
    {
        printf ("Molim unesite tezinu za atribut %d: ",i);
        scanf ("%f",&W[i]);
    }
}

void Unos ()
{
    int odabir;
    printf ("Program za agregaciju atributa\n");
    printf ("Unesite broj atributa - L: ");
    scanf ("%d",&L);
    printf ("Molim odaberite\nZa jednake tezine aributa 1\nZa nejednake tezine i unos pojedinačnih
tezina 2\n");
    printf ("Vas unos je: ");
    scanf ("%d",&odabir);
    if (odabir == 1)
    {
        w=br1/L;
        Osnovne_tezine1 ();
    }
    if (odabir==2)
    {
        //Unos_tezina ();
        Osnovne_tezine2 ();
    }
    if ((odabir!=1) && (odabir!=2))
    {
        printf("Pogresan odabir, molim ponovite unos");
        Unos ();
    }
}
```

```
        }  
    }  
  
void main()  
{  
    int odabir;  
    Unos ();  
    Kombinirane ();  
    printf ("Zelite li izracun kobiniranih stupnjeva uvjerenja za prijasnju agregaciju\nOdaberite 1) za  
Da i 2) za ne\n");  
    scanf ("%d",&odabir);  
    if (odabir==1) CombiDB ();  
    printf ("\nZelite li izracun ocekivanog utilitya i utility intervala za dobivene  
vrijednosti\nOdaberite 1) za Da i 2) za ne\n");  
    scanf ("%d",&odabir);  
    if (odabir==1) Utility ();  
}
```

Prilog 2. Osnovni kod aplikacije za sivo predviđanje

```
#include <iostream>
#include <iomanip>
#include <math.h>
#include <string>
#include <fstream>
using namespace std;

// Globalne varijable:
int n;
double X0[20];
double X1[20];
double Z1[20];
double Y[20];
double a;
double b;
double X0_kapa[21];
double X1_kapa[21];
double error[21];
double AVGerr;
std::string ime;
//ime+=" ".txt";
ofstream output;

// Prototipi funkcija:
void ispisPolja (double*, int, string);
void ispisPoljaNaEkran (double *p, int n, string ime);
void unosX0();
void generirajX1();
void generirajZ1();
void Parametarski_ab();
void LSM_ab();
void generirajX1_kapa();
void generirajX0_kapa();
void RacunPogreske();
void predictTest();
void clear();
```

```
int main()
{
    string repeat = "Ponovi";
    while (repeat != "e")
    {
        string test_pogreske = "Ne racunaj";
        string metoda = "parametar";
        cout << "Unesite ime datoteke u koju želite spremiti podatke:\n(0 za default
(log.txt))"<<endl;
        cin >> ime;
        if (ime!="0")
        {
            ime+="\n.txt";
            output.open(ime.c_str(), ios_base::app);
        }
        else
        {
            output.open("log.txt");
        }
        cout << endl;
        clear();
        // Izracunaj:
        unosX0();
        generirajX1();
        generirajZ1();
        cout << "\nOdaberite metodu trazenja parametara:\n(0 za default (parametarska), m - za
LSM metodu)\n";
        cin >> metoda;
        // Odabir metode racunanja parametara (LSM radi na temelju samo 4 unosa, par može
do 20):
        if (metoda=="m") LSM_ab();
        else Parametarski_ab();
        generirajX1_kapa();
        generirajX0_kapa();
        RacunPogreske ();
        ispisPoljaNaEkran(X0,n,"X0 (originalni niz)");
        ispisPoljaNaEkran(X0_kapa,n+1,"X0_kapa (predvidjeni niz)");
        ispisPoljaNaEkran(error,n,"Pogreske");
        // Zapisi podatke u datoteku:
        ispisPolja(X0,n,"X0");
```

```
    ispisPolja(X1,n,"X1");
    ispisPolja(Z1,n,"Z1");
    ispisPolja(X1_kapa,n+1,"X1_kapa");
    ispisPolja(X0_kapa,n+1,"X0_kapa");
    ispisPolja(error,n,"Pogreske");
    // Racun pogreske za predvidjenu vrijednost (unos se izmjerena):
    cout << "\nZelite li provjeriti racun pogreske za \npredvidenu vrijednost uz unos
poznate?\n(d - zelim)"<<endl;
    cin >> test_pogreske;
    if (test_pogreske == "d")
    {
        predictTest();
    }
    output.close();
    // Ponavljanje racunanja, da ili ne?, e za exit, sve ostalo za opet
    cout << "\nZelite li ponovno pokrenuti program? \n(e - exit)"<<endl;
    cin >> repeat;
}
return 0;
}
//Definicije funkcija

// Ispis polja podataka
void ispisPolja (double *p, int n, string ime)
{
    output<<ime<<":"<<endl;
    output <<endl<<left<<"\t[ ";
    for (int i=0;i<n;i++)
    {
        output<<setw(12)<<left<<p[i];
    }
    output<<setw(12)<<"]\n"<<endl;
}

// Ispis polja podataka na ekran
void ispisPoljaNaEkran (double *p, int n, string ime)
{
    cout<<ime<<":"<<endl;
    cout <<"\t";
    for (int i=0;i<n;i++)
```

```
{
    cout<<setw(12)<<left<<p[i];
}
cout<<"\n"<<endl;
}

// Unos broja elemenata X0 i učitavanje podataka
void unosX0()
{
    cout << "Molim unesite broj elemenata 1D polja X0: ";
    cin >> n;
    if (n<1)
        n=1;
    if (n>20)
        n=20;
    for (int i=0;i<n;i++)
    {
        cout << "Molim unesite ["<<i<<"] element polja X0: ";
        cin >> X0[i];
    }
}

// Generiranje X1
void generirajX1 ()
{
    X1[0]=X0[0];
    for (int i=1;i<n;i++)
    {
        X1[i]=X1[i-1]+X0[i];
    }
}

// Generiranje Z1
void generirajZ1()
{
    Z1[0]=0;
    for (int i=1;i<n;i++)
    {
        Z1[i]=0.5*X1[i]+0.5*X1[i-1];
    }
}
```



```
}

// Dobivanje parametara a i b parametarskom metodom:
void Parametarski_ab()
{
    double C,D,E,F;
    C=D=E=F=0;
    for (int i=1;i<n;i++)
    {
        C+=Z1[i];
        D+=X0[i];
        E+=Z1[i]*X0[i];
        F+=Z1[i]*Z1[i];
    }
    a=(C*D-(n-1)*E)/((n-1)*F-C*C);
    b=(D*F-C*E)/((n-1)*F-C*C);
    output <<"\nParametar a (parametarska metoda): "<< a << "\n";
    output <<"Parametar b (parametarska metoda): "<< b << "\n\n"<<endl;
    cout << "Parametri a i b generirani parametarskom metodom!\n"<<endl;
}

// Generiranje X1_kapa:
void generirajX1_kapa()
{
    X1_kapa[0]=X0[0];
    for (int i=1;i<n+1;i++)
    {
        X1_kapa[i]=X0[0]*exp(-a*i)+(b/a)*(1-exp(-a*i));
    }
}

// Generiranje X0_kapa:
void generirajX0_kapa()
{
    X0_kapa[0]=X0[0];
    for (int i=1;i<n+1;i++)
    {
        X0_kapa[i]=(1-exp(a))*(X0[0]-(b/a))*exp(-a*i);
    }
}
```

// Racunanje pogreske:

void RacunPogreske()

```
{
    double sum=0;
    for (int i=0;i<n;i++)
    {
        error[i]=fabs((X0[i]-X0_kapa[i])/X0[i])*100;
        sum+=error[i];
    }
    AVGerr=sum/n;
    output << "\nProsjecna pogreska: "<<AVGerr<<"\n"<<endl;
}
```

// Provjera ispravnosti predviđanja:

void predictTest()

```
{
    double val;
    cout << "Unesite izmjerenu vrijednost: ";
    cin >> val;
    cout << "Predvidjena vrijednost je: "<<X0_kapa[n]<<endl;
    cout << "Pogreska: "<< fabs((X0_kapa[n]-val)/val)*100<<"%."<<endl;
}
```

// Ciscenje podataka za ponovni rad:

void clear ()

```
{
    for (int i=0;i<21;i++)
    {
        a=b=n=AVGerr=0;
        if (i<20)
        {
            X0[i]=X1[i]=Z1[i]=Y[i]=0;
        }
        X0_kapa[i]=X1_kapa[i]=error[i]=0;
    }
}
```

// LSM racunjanje a i b:

void LSM_ab ()

```
{
    double Y[19][1], B[19][2], Bt[2][19], UmB[2][2]={}, Mt[2][2], M[2][2], MBt[2][19]={},
    ab[2][1]={};
    // popunjavanje Y i B matrica
    for (int i=1; i<n; i++)
    {
        Y[i-1][0]=X0[i];
        for (int j=0; j<2; j++)
        {
            if (j==0)
                B[i-1][j]=-Z1[i];
            else
                B[i-1][j]=1;
        }
    }
    // Transponiranje B da se dobije Bt
    for (int i=0; i<2; i++)
    {
        for (int j=0; j<n-1; j++)
        {
            Bt[i][j]=B[j][i];
        }
    }

    //Množenje Bt i B:
    for (int i=0; i<2; i++)
    {
        for (int j=0; j<2; j++)
        {
            for (int k=0; k<n-1; k++)
            {
                UmB[i][j]+=Bt[i][k]*B[k][j];
            }
            M[i][j]=UmB[i][j];
        }
    }

    // Racunanje inverza matrice M = (Bt*B)^(-1):
    double detA = M[0][0]*M[1][1]-M[0][1]*M[1][0];
    if (detA <=0)
```

```
{
    cout << "Determinanta matrice <= 0, \nnazalost nije moguće rabiti LSM metodu.
\nPrebacujem na parametarsku!"<<endl;
    Parametarski_ab();
}
else
{
    double indet = 1/detA;
    Mt[0][0]= M[1][1];
    Mt[0][1]=-M[0][1];
    Mt[1][0]=-M[1][0];
    Mt[1][1]= M[0][0];
    for (int i=0;i<2;i++)
    {
        for (int j=0;j<2;j++)
        {
            M[i][j]=Mt[i][j]*indet;
        }
    }
    // Množenje M sa Bt:
    for (int i=0; i<2;i++)
    {
        for (int j=0; j<n-1; j++)
        {
            for (int k=0;k<2;k++)
            {
                MBt[i][j]+=M[i][k]*Bt[k][j];
            }
        }
    }

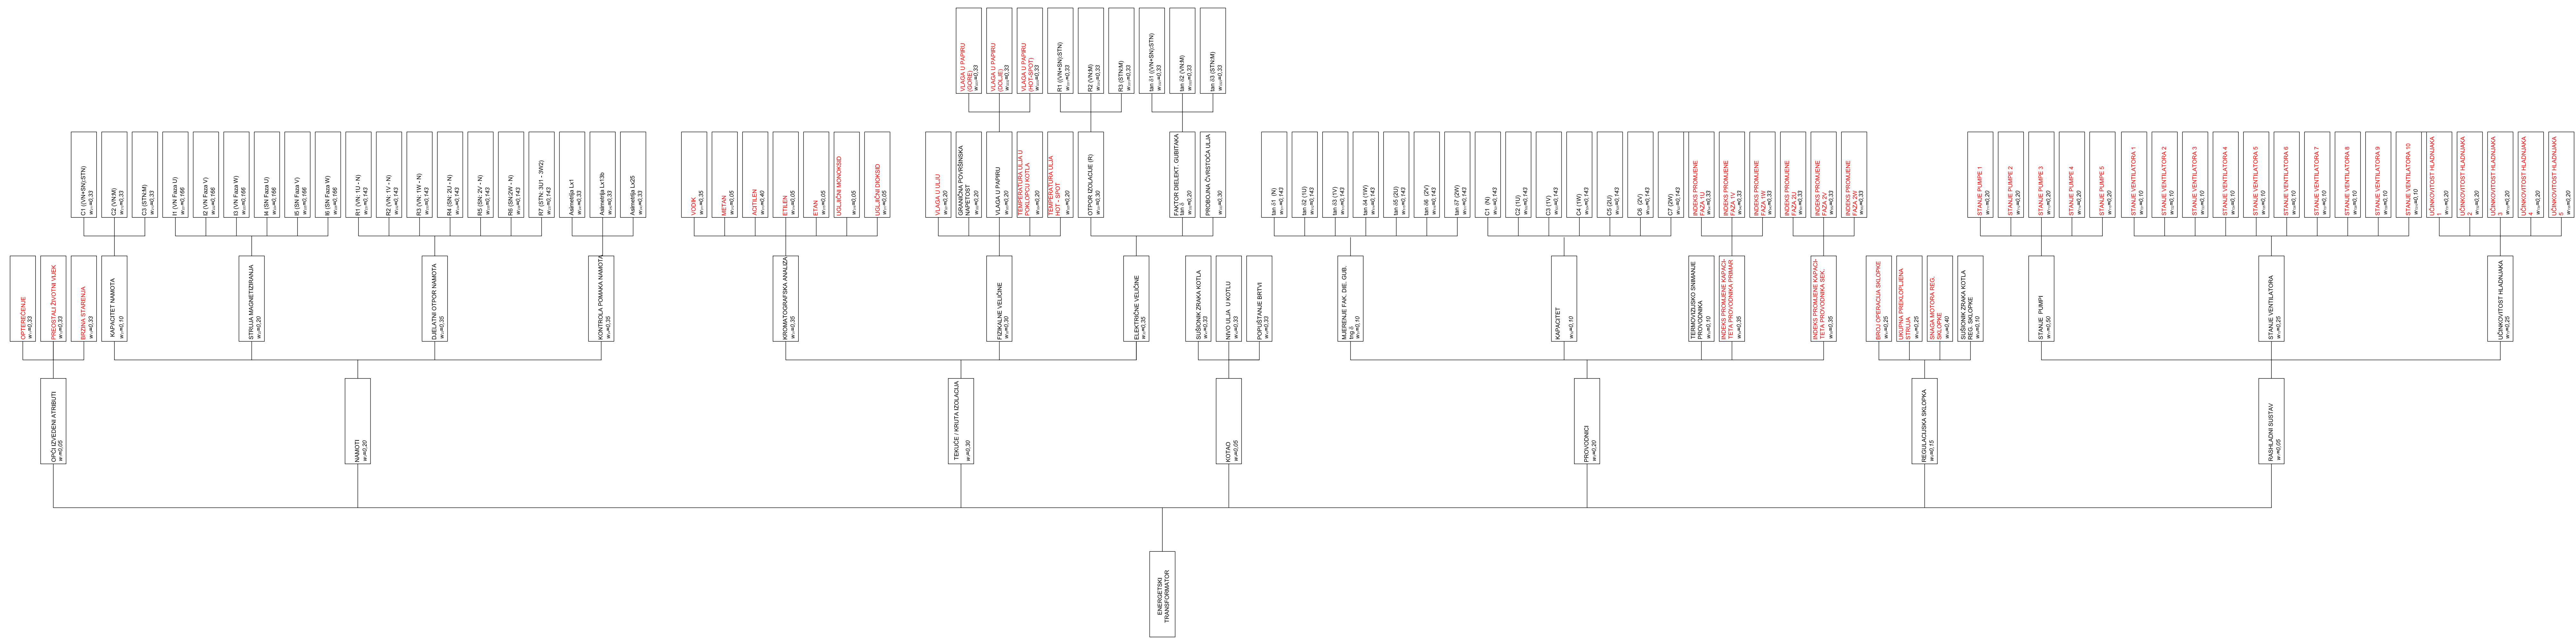
    // Množenje MBt sa Y:
    for (int i=0;i<2;i++)
    {
        for (int j=0;j<1;j++)
        {
            for(int k=0;k<n-1;k++)
            {
                ab[i][j]+=MBt[i][k]*Y[k][j];
            }
        }
    }
}
```

```
    }
}
a = ab[0][0];
b = ab[1][0];
output << "\nParametar a (LSM): "<<a<<endl;
output << "Parametar b (LSM): "<<b<<"\n\n"<<endl;
cout << "Parametri a i b generirani LSM metodom!\n"<<endl;
// Ispis Y
output << "Y: "<<endl;
for (int i=0;i<n-1;i++)
{
    output << "\t"<< Y[i][0];
    output << endl;
}
output <<endl;
// Ispis B
output << "B: "<<endl;
for (int i=0;i<n-1;i++)
{
    for (int j=0;j<2;j++)
    {
        output << "\t"<< B[i][j]<<"\t";
    }
    output << endl;
}
output <<endl;
}
}
```

Prilog 3. Grafički prilozi

P.3. Slika 7.3. Dekompozicijski model energetskog transformatora

P.3. Tablica 7.2. Kvantitativni i kvalitativni podaci



NAZIV ATRIBUTA
W_{atr}

- podaci dobiveni mjerenjem ili procjenom (tzv. *offline* podaci)

NAZIV ATRIBUTA
W_{atr}

- podaci dobiveni iz sustava za udaljeni nadzor (tzv. *online* podaci)

W_{atr}

- težine pojedinih osnovnih ili općih atributa

KROMATOGRAFSKA ANALIZA (0,35)							TEKUĆE/KRUTA IZOLACIJA (0,3)										ELEKTRIČNE VELIČINE (0,3)						
Vodik	Metan	Acetilen	Etilen	Etan	Ugljični monoksid	Ugljični dioksid	Vlaga u ulju	Granična površinska napetost	VLAGA U PAPIRU (0,2)			Temperatura ulja u poklopcu kotla	Temperatura ulja Hot-Spot	Otpor izolacije (0,33)			Faktor dielektričnih gubitaka (tan δ) (0,33)			Probojna čvrstoća ulja (0,33)			
									Vlaga u papiru (gore)	Vlaga u papiru (dolje)	Vlaga u papiru (hot-spot)			R1 ((VN+SN):STN)	R2 (VN:M)	R3 (STN:M)	tan δ1 ((VN+SN):STN)	tan δ2 (VN:M)	tan δ3 (STN:M)				
0,350 23	0,050 24	0,400 25	0,050 26	0,050 27	0,050 28	0,050 29	0,200 30	0,200 31	0,333 32	0,333 33	0,333 34	0,200 35	0,200 36	0,333 37	0,333 38	0,333 39	0,333 40	0,333 41	0,333 42	0,333 43			
μl/l (ppm)	μl/l (ppm)	μl/l (ppm)	μl/l (ppm)	μl/l (ppm)	μl/l (ppm)	μl/l (ppm)	mg/kg	mN/m (na 20 oC)	%	%	%	°C	°C	GΩ (10 min)	GΩ (10 min)	GΩ (10 min)	%	%	%	kV			
78	5	<0,1	<0,1		0,4	342	469	6												91,1			
76	6	<0,1	<0,1	<0,1		356	445	2						175,35	149,1	84							
83	9	0		0,4		432	686	4												98,6			
86	9	0		0	0,9	454	678	3															
71	9	0		0	1	477	928	6		42				184,92	150,33	107,37	0,16	0,37	0,14	65			
65	10	0		0	1,7	468	722	4															
60	13	0		0	5	537	1053	6												73,5			
52	14	0		0	3	614	1247	6						93,8	71,4	50,4				94,6			
38	14	1		1	3	568	1340	3		1,59	1,98	1,5	33	34									
35	16	1		2	3	584	1620	3		1	1,14	1	42	43									
29	15	1		2	4	639	2004	3		1,23	1,46	1,22	50	55						94,3			
30	19	2		1	7	650	1950	3		1,11	1,27	1	44	47									
39	20	2		2	11	720	2552	3		1,07	1,24	1,02	44	47	142,75	87,24	60,4	0,21	0,43	0,18			
3,5	5	5	5	5	3	5	5	5												4,5			
3,5	5	5	5	5	3	5	5	5						5	5	5							
3	5	5	5	5	3	5	5	5												5			
3	5	5	5	5	3	5	5	5															
3,5	5	5	5	5	3	5	5	5		5				5	5	5	5	5	5	3			
4	5	5	5	5	2	5	5	5															
4	4,5	5	5	5	2	5	5	5												3			
4	4,5	5	5	5	2	5	5	5						5	5	5				5			
4,5	4,5	5	5	5	2	5	5	5		4	3	4	5	5									
4,5	4,5	5	5	5	2	4	5	5		5	5	5	5	5									
5	4,5	5	5	5	2	4	5	5		4	4	4	4	5	5					5			
5	4	5	5	5	1	4	5	5		5	4	5	5	5									
4,5	4	5	5	4,5	1	4	5	5		5	4	5	5	5	5	5	5	5	5				
<37,5 ppm	<15 ppm	<32,5 ppm	<22,5	<10	<162,5	<1430	<8	>=35	<1,2	<1,2	<1,2	<78	<98	>10000 MΩ	>10000 MΩ	>5000 MΩ	< 0,5 %	< 0,5 %	< 0,5 %	> 90			
<75	<30	<65	<45	<20	<325	<2865	<12	>30	<1,6	<1,6	<1,6	<84	<104	<10000 MΩ	<10000 MΩ	<5000 MΩ	< 1	< 1	< 1	>80			
<112,5	<45	<97,5	<67,5	<30	<487,5	<4300	<14	>25	<2,3	<2,3	<2,3	<90	<110	<4000 MΩ	<4000 MΩ	<2000 MΩ	< 1,5	< 1,5	< 1,5	>65			
<150	<60	<130	>90	<40	<650	<5730	<16	>20	<2,8	<2,8	<2,8	<96	<116	<2000 MΩ	<1800 MΩ	<800 MΩ	<2	<2	<2	>50			
>150	>60	>130	>90	>40	>650	>5730	>16	<=20	>= 2,8	>= 2,8	>= 2,8	>96	>116	<1000 MΩ	<900 MΩ	<400 MΩ	>=2	>=2	>=2	<50			

REGULACIJSKA SKLOPKA (0,15)				RASHLADNI SUSTAV (0,05)																			
Broj operacija sklopke	Ukupna preključena struja	Snaga motora reg. sklopke	Sušionik zraka kotla reg. sklopke	STANJE PUMPI (0,5)					STANJE VENTILATORA (0,25)										UČINKOVITOST HLADNJAKA (0,25)				
				Stanje pumpe 1	Stanje pumpe 2	Stanje pumpe 3	Stanje pumpe 4	Stanje pumpe 5	Stanje ventilatora 1	Stanje ventilatora 2	Stanje ventilatora 3	Stanje ventilatora 4	Stanje ventilatora 5	Stanje ventilatora 6	Stanje ventilatora 7	Stanje ventilatora 8	Stanje ventilatora 9	Stanje ventilatora 10	Učinkovitost hladnjaka 1	Učinkovitost hladnjaka 2	Učinkovitost hladnjaka 3	Učinkovitost hladnjaka 4	Učinkovitost hladnjaka 5
0,250	0,250	0,400	0,100	0,200	0,200	0,200	0,200	0,200	0,100	0,100	0,100	0,100	0,100	0,100	0,100	0,100	0,100	0,100	0,200	0,200	0,200	0,200	0,200
68	69	70	71	72	73	74	75	76	77	78	79	80	81	82	83	84	85	86	87	88	89	90	91
KA	%																						
			u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji					
			u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji					
			u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji					
			u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji					
			u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji					
			u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji					
			u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji					
1150	0	0	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	10,78	39,07	35,26	29,71	5,01
1152	0,2	0	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	60	16,87	15	57	42,5
1155	0	0	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	33,27	6,61	3,22	37,35	29,2
1161	0,1	0	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	30,58	4,93	3,92	28,03	23,96
		0	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	u funkciji	9,8	52,16	55,61	17,9	6,1
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5	5	5	5					
			5	5	5	5	5	5	5	5	5	5	5	5	5								